

**VŠB – Technická univerzita Ostrava**  
**Fakulta elektrotechniky a informatiky**  
**Katedra kybernetiky a biomedicínského inženýrství**

# **DIPLOMOVÁ PRÁCE**

2019

Bc. Jan Suchánek

**VŠB – Technická univerzita Ostrava**  
**Fakulta elektrotechniky a informatiky**  
**Katedra kybernetiky a biomedicínského inženýrství**

**Detekce poruch chůze u osob s Parkinsonovou  
nemocí**

Detection of Gait Disorders in People with Parkinson's  
Disease

VŠB - Technická univerzita Ostrava  
Fakulta elektrotechniky a informatiky  
Katedra kybernetiky a biomedicínského inženýrství

## Zadání diplomové práce

Student:

**Bc. Jan Suchánek**

Studijní program:

N2649 Elektrotechnika

Studijní obor:

3901T009 Biomedicínské inženýrství

Téma:

**Detekce poruch chůze u osob s Parkinsonovou nemocí**  
**Detection of Gait Disorders in People with Parkinson's Disease**

Jazyk vypracování:

čeština

Zásady pro vypracování:

1. Seznámení se s metodami a technikami pro měření pohybových aktivit a kvalit chůze.
2. Rešerše stávajícího stavu problematiky detekce poruch chůze pacientů s Parkinsonovou nemocí.
3. Návrh struktury experimentu pro měření parametrů chůze s využitím systému XSENS a vybavení biomechanické laboratoře VŠB-TUO u osob s Parkinsonovou nemocí se zajištěním synchronizace mezi jednotlivými měřicími přístroji.
4. Ověření proveditelnosti navrhovaného experimentu na dostatečném počtu osob, návrh a realizace systému pro archivaci prováděných měření.
5. Výběr parametrů chůze vhodných pro detekci poruch chůze způsobených Parkinsonovou nemocí.
6. Extrakce vybraných parametrů chůze, jejich srovnání mezi skupinou zdravých a nemocných osob.
7. Zhodnocení dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] BIENKIEWICZ, Marta M. N., Cathy CRAIG a Marta M. N. BIENKIEWICZ. *Sound, Music and Movement in Parkinson's Disease*. Lausanne: Frontiers Media, c2017. ISBN 978-2889450794.
- [2] BARBIERI, Fabio Augusto, Rodrigo VITÓRIO a Marta M. N. BIENKIEWICZ. *Locomotion and Posture in Older Adults: The Role of Aging and Movement Disorders*. Springer, Cham: Springer International Publishing AG, 2017. Online ISBN 978-3-319-48980-3.
- [3] LEVINE, David, Jim RICHARDS a Michael W. WHITTLE. *Whittle's Gait Analysis*. London: Elsevier Health Sciences, c2012. ISBN 0702051993.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **doc. Ing. Martin Černý, Ph.D.**

Datum zadání: 01.09.2018

Datum odevzdání: 12.07.2019



doc. Ing. Jiří Kozírek, Ph.D.  
*vedoucí katedry*

prof. Ing. Pavel Brandštetter, CSc.  
*děkan fakulty*

## PROHLÁŠENÍ STUDENTA

„Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.“

V Ostravě 29.4.2019

  
.....

Podpis studenta

# PODĚKOVÁNÍ

Tímto bych chtěl poděkovat doc. Ing. Martinu Černému, Ph.D. za vedení mé bakalářské práce, cenné rady a odborný dohled. Mé poděkování patří také Ing. Radku Halfarovi, za cenné rady při praktické realizaci. Dále bych chtěl poděkovat Ing. Jiřímu Kohutovi, za cenné rady při měření experimentu.

## ABSTRAKT

Hlavním cílem této diplomové práce, je navrhnout algoritmus detekce zamrznutí pohybu pacientů s Parkinsonovým onemocněním. Součástí diplomové práce je navrhnutí experimentu pro získání jednotných kvalifikujících dat z měření 2 skupin. Skupina kontrolní a skupina s Parkinsonovým onemocněním. Experiment využívá přístroje Xsens Awinda a přístroje Novel Emed-XL. Měření na těchto přístrojích je synchronizované hardwarově a výsledky vyexportovány a nahrány do vytvořené databáze v jazyce MySQL, která je dostupná na Google Cloud SQL serveru. Experiment je navrhnut podle TUG testu, kdy jsou osobám pokládány jednoduché matematické otázky pro odvedení pozornosti od prováděného měření, aby u pacientů s parkinsonovým onemocněním došlo během měření k zamrznutí pohybu. Detekce zamrznutí pohybu je prováděna na datových setech, které byly k dispozici před začátkem měření. K detekci byly využity neuronové sítě neural network time series a neural network pattern recognition. V budoucnosti by toto řešení mohlo sloužit ke kontrolování stavu pacienta.

*Klíčová slova: Parkinsonovo onemocnění, neuronová síť, zamrznutí pohybu, detekce zamrznutí pohybu*

## ABSTRACT

The main aim of this master thesis is to design algorithm for detection of freezing of gait of patients with parkinson's disease. Part of the thesis is to design an experiment for obtaining uniform qualifying data frm measurements of 2 groups. Control group and Parkinson's disease group. The experiment uses Xsens Awinda and Novel Emed-XL. Measurements on these devices are synchronized by hardware and the results are exported and uploaded to MySQL database which was created on and is available on Google Cloud SQL server. The experiment is designed according to the TUG test, where people are asked simple math questions to divert their attention from the measurements being made, so that patients with parkinson's disease experience freezing during the measurement. Detection of gait is performer on datasets that were available before the measurement started. Neural network time series and neural network pattern recognition were used for detection. In the future, this solution couldl serve to control the patient's condition.

*Keywords: Parkinson disease, neural network, freezing of gait, detection of freezing of gait*

# OBSAH

Seznam ilustrací a tabulek.....	10
Seznam použitých symbolů a zkratk .....	12
Úvod.....	13
Teoretická část .....	14
1. Literární rešerše.....	14
1.1 Segmentation of Gait Sequences in Sensor-Based Movement Analysis: A Comparison of Methods in Parkinson's Disease [1] .....	14
1.2 Detecting freezing of gait with a tri-axial accelerometer in Parkinson's disease patients [2].....	19
1.3 Feedforward Neural Network for Time Series Anomaly Detection [10].....	24
2. Teoretický rozbor .....	27
2.1 Parkinsonova nemoc.....	27
2.2 Historie .....	27
2.3 Anatomie a fyziologie .....	27
2.4 Vyšetřovací metody.....	33
2.5 Zobrazovací metody .....	34
2.6 Definování chůze.....	34
2.7 Metody získání dat .....	37
2.7.1 Akcelerometrie - Xsens Awinda .....	38
2.7.2 Dynamická plantografie – Novel Emed-XL.....	40
2.8 Neuronová síť .....	41
2.8.1 Biologický neuron .....	41
2.8.2 Matematický model neuronu .....	42
2.8.3 Matematický model neuronové sítě.....	42
2.8.4 Klasické modely neuronových sítí .....	42
2.8.5 Učení neuronové sítě .....	44
2.8.6 Zpětnovazební síť.....	44
2.8.7 Klasifikace.....	45
2.8.8 Mělké neuronové sítě .....	46
3. Vlastní zpracování práce .....	51
3.1 Návrh řešení experimentu .....	51



3.1.1	Průběh měření jednotlivých přístrojů .....	52
3.1.2	Synchronizace použitého vybavení .....	54
3.2	Návrh databáze pro uložení naměřených dat.....	59
3.3	Návrh algoritmu .....	60
3.3.1	Zpracování datových setů.....	63
3.4	Výstup měření experimentu .....	68
3.5	Navrhnutí algoritmu detekce zamrznutí pohybu .....	71
3.5.1	Neural Net Pattern Recognition.....	72
3.5.2	Neural Net Time Series .....	77
Závěr .....		83
Literatura .....		84
Seznam příloh.....		87

# SEZNAM ILUSTRACÍ A TABULEK

Obr. č. 1: Topologie dvojstupňového hierarchického skrytého Markovova modelu (hHMM). .....	16
Obr. č. 2: (vlevo) Umístění senzoru Shimmer a definice os; (vpravo) Údaje o akcelerometru a gyroskopu pro jeden příkladný krok. ....	18
Tab. č. 1: Počet oken (před agregací) v každé sadě dat, které se používají pro označení FOG .....	21
Tab. č. 2: Plná sada funkcí používaných pro detekci FOG. Naproti tomu redukováná sada funkcí zahrnuje pouze rychlou Fourierovu transformaci (tj. Index 1).....	21
Tab. č. 3: Matice záměn .....	25
Obr. č. 3: Návrh systému neuronové sítě. ....	25
Obr. č. 4: Architektura hluboké dopředné neuronové sítě. ....	26
Obr. č. 5: Popis umístění chodidel na podložce. [4].....	35
Obr. č. 6: Batoh obsahující přístroj Xsens MVN Awinda. [17].....	38
Obr. č. 7: Pohybový senzor (MTw). [17].....	38
Obr. č. 8: Awinda spojovací stanice. [17] .....	39
Obr. č. 9, 10: Rozložení pohybových senzorů MTw. [17].....	39
Obr. č. 11: Novel Emed-XL. ....	40
Obr. č. 12: Biologický neuron. [15] .....	41
Obr. č. 13: Formální neuron. [15] .....	42
Obr. č. 14: Architektura sítě perceptronů. [14] .....	43
Obr. č. 15: Vícevrstvá neuronová síť. [16].....	43
Obr. č. 16: Jednoduchá zpětnovazební síť. [18].....	44
Tab. č. 4: Matice záměn .....	45
Obr. č. 17: Křivka sigmoidní aktivační funkce. [21].....	47
Obr. č. 18: Příklad funkčnosti aktivační funkce softmax. [22] .....	47
Obr. č. 19: navrhnutý TUG test.....	51
Tab. č. 5: Měřené rozměry potřebné k vytvoření profilu v programu XSens MVN [17]. ....	52
Obr. č. 20: Průběh měření v softwaru Xsens MVN Analyze. ....	53
Obr. č. 21: Zobrazení průběhu měření s přístrojem Novel Emed-XL.....	54
Obr. č. 22: Zobrazení průběhu měření a výstupních dat přístroje Novel Emed-XL. ....	54
Obr. č. 23: Připojení synchronizace k přístroji Xsens Awinda. ....	55
Obr. č. 24: Připojovací konektory přístroje Emed-XL. ....	56
Obr. č. 25: Synchronizační koaxiální kabely přístroje Novel Emed-XL. ....	56
Obr. č. 26: Sparkfun logic level convertor. ....	57

Obr. č. 27: Schéma jednoho kanálu Logic Level Converteru [20].....	57
Obr. č. 28: Synchronizovaná data z měření na přístrojích .....	58
Obr. č. 29: Relace databáze.....	59
Obr. č. 30: Rozložení senzorů v datovém setu Gait in Parkinson disease.....	61
Obr. č. 31: Umístění senzorů v datovém setu Daphnet Freezing of Gait Data Set. [datový set 2] .....	62
Obr. č. 32: Vývojový diagram zpracování datových setů. ....	63
Obr. č. 33: Frekvenční charakteristika low pass FIR filtru použitého k odfiltrování šumu. ....	64
Obr. č. 34: Ukázka vlivu aplikovaného dolnoproustného filtru na data z tlakového senzoru [datový set 1]. ....	64
Obr. č. 35: Ukázka detekování vrcholů v signálu z obrázku č 35.....	65
Tab. č. 6: Porovnání rozdílů v parametru chůze kontrolní skupiny se skupinou pacientů s Parkinsonovým onemocněním. ....	67
Tab. č. 7: Vypočítané hodnoty parametrů chůze v experimentu. ....	69
Tab. č. 8: Porovnání parametrů chůze mezi kontrolními skupinami v datových setech a měřené skupině v experimentu.....	69
Obr. č. 36 Základní model neuronové sítě. ....	71
Tab. č. 9: Výsledky trénování NNPR.....	72
Obr. č. 37: Matice záměn trénování modelu NNPR.....	73
Obr. č. 38: Graf ROC. ....	74
Obr. č. 39: Matice záměn NNPR na prvních testovacích datech. ....	75
Obr. č. 40: Graf ROC testovacích dat pro první testovací data.....	75
Tab. č. 10: Výsledky testování NNPR. ....	76
Obr. č. 41: Obecné schéma nelineárního NNTS modelu. ....	77
Tab. č. 11: Výsledky trénování NNTS.....	77
Obr. č. 42: Graf regrese trénování NNTS. ....	78
Obr. č. 43: Výstup trénování se znázorněnými chybami. ....	78
Tab. č. 12: Výsledky testování NNTS.....	79
Obr. č. 44: Výstup testování 1 se znázorněnými chybami. ....	79
Obr. č. 45: Výstup testování 2 se znázorněnými chybami. ....	80
Obr. č. 46: Výstup testování 3 se znázorněnými chybami. ....	80
Obr. č. 47: Výstup testování 4 se znázorněnými chybami. ....	81
Obr. č. 48: Výstup testování 7 se znázorněnými chybami. ....	81
Tab. č. 13: Výsledné přesnosti testovaných NN .....	82

## SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

PD	Parkinsonova nemoc
FOG	Zamrznutí pohybu
DTW	Dynamické časové zkreslení
HMM	Hierarchické Markovy modely
UPDRS	Unified Parkinson's Disease Rating Scale“, neboli Sjednocené hodnocení škály onemocnění Parkinsna
TUG	Zkratka testu „Timed up and go“, neboli měření postavení a ujití několika metrů
NN	Neuronová síť
NNTS	Neuronová síť k detekci anomálií v čase
NNPR	Neuronová síť k rozlišení tříd

# ÚVOD

Cílem práce je vytvoření algoritmu pro detekci zamrznutí pohybu u pacientů s Parkinsonovým onemocněním. Parkinsonové onemocnění je degenerativní onemocnění, které postihuje převážně starší osoby, ovšem nevyhnu se jí ani osoby mladší 60 let. Toto onemocnění je následkem nedostatku dopaminu. Průběh tohoto onemocnění je provázen poruchami hybnosti, které lze detekovat pomocí motorických senzorů. Využití motorických senzorů k detekci právě poruch hybnosti nebo zamrznutí pohybu se využívá z důvodu lepší kontroly a větší bezpečnosti pacienta.

Před vytvořením algoritmu detekce zamrznutí pohybu byl navrhnout experiment k provedení měření na kontrolní skupině s využitím přístrojů Xsens Awinda a Novel Emed-XL. Experiment byl navrhnout v podobě TUG testu ve 2 variantách, které měli za úkol měřenou osobu dostat do kritického momentu pro pacienta s Parkinsonovým onemocněním. Určité části experimentu byly navrhnuty tak, aby pacienti s Parkinsonovým onemocněním provázelo zamrznutí pohybu.

Rešeršní část byla zpracována na témata detekování zamrznutí pohybu, detekce jednotlivých fází chůze pomocí inerciálních senzorů a návrhu neuronových sítí pro detekci abnormalit v datech.

Teoretická část se zabývá Parkinsonovým onemocněním, jeho anatomii a fyziologií, ale také popisem jednotlivých fází krokového cyklu a jejich detekci. Následně se zaměřuje na neuronové sítě a jejich

Část vlastního vypracování začíná seznámením se s přístroji Xsens Awinda a Novel Emed-XL, kde jsou popsány důležité části těchto přístrojů k provedení experimentu. Další částí je synchronizování těchto přístrojů pro zajištění kvalitních a korektních dat pro možnosti budoucího využití. Následně je popsáno vytvoření databáze pro nahrávání naměřených dat a budoucí práci s touto databází. Poslední část se zaměřuje na vytvoření algoritmu detekce zamrznutí pohybu s využitím neuronových sítí. Evaluace vyplývá z porovnání získaných výsledků s výsledky chtěnými.

# TEORETICKÁ ČÁST

## 1. LITERÁRNÍ REŠERŠE

### 1.1 Segmentation of Gait Sequences in Sensor-Based Movement Analysis: A Comparison of Methods in Parkinson's Disease [1]

Robustní segmentace chůze je základem analýzy mobilní chůze. Pro segmentaci chůze zdravých a patologických záchvatů chůze byla použita řada metod. Tato práce vytvořila jednotné hodnocení metod segmentace chůze u Parkinsonovy nemoci (PD).

V tomto příspěvku porovnávají čtyři převládající metody segmentace chůze, aby odhalili jejich silné stránky a nevýhody při zpracování chůze.

- detekci špiček, metoda založená na událostech,
- dvou variantách dynamického časového zkreslení z metod shromáždění šablon
  - Euklidovská DTW (eDTW)
  - Pravděpodobnostní DTW (pDTW)
- hierarchických skrytých Markových modelů (hHMM) z metod strojového učení.

## Metody

### Detekce špiček

Identifikace špiček v dané datové sekvenci je důležitá v mnoha aplikacích, neboť často signalizují významné události v signálu.

Formulace metody špičkové detekce závisí na specifických charakteristikách signálu. Obvykle však musí být splněny dva základní požadavky pro identifikaci datového bodu. Především by velikost signálu měla být vyšší než určitá prahová hodnota, která může být nastavena na základě charakteristik signálu. Navíc minimální doba mezi dvěma po sobě jdoucími špičkami musí být větší než určitá prahová hodnota, aby se zabránilo nalezení dvou nebo více vrcholů v jednom kroku.

Jiné požadavky mohou být použity stejně jako např. První a druhý derivát signálu mohou splňovat určitá kritéria. Při provádění těchto přímých kroků můžeme segmentovat krok pomocí identifikovaných vrcholů.

### Multi-subsekvenční Dynamické Časové Zkreslení (DTW)

Obecně se DTW používá k nalezení podobnosti mezi dvěma sekvencemi časových řad. msDTW je rozšíření DTW s cílem najít více subsekvencí ve větší sekvenci, z nichž každá je podobná dané kratší sekvenci. Segmentací sekvence do kroků byla vytvořena šablona a pokoušeli se najít několik sekvencí v pořadí, z nichž každá byla podobná šabloně. Algoritmus msDTW je následující:

Obecně se DTW používá k nalezení podobnosti mezi dvěma sekvencemi časových řad. msDTW je rozšíření DTW s cílem najít více subsekvencí ve větším pořadí, z nichž každá je podobná dané kratší sekvenci. Segmentace sekvence do kroků jsme vytvořili šablonu a pokoušeli jsme se najít několik sekvencí v pořadí, z nichž každá byla podobná šabloně. Algoritmus msDTW je následující:

- Dálková matice D: Elementy D reprezentují dvojici vzdáleností mezi prvky šablony X a posloupnosti Y. Velikost matice D je  $M \times T$ . V případě zahrnutí několika os, jsou vypočítány oddělené matice vzdálenosti a všechny jsou shrnuty tak, že vytvoří jednu matici vzdálenosti
- Maticová kostka C: představuje vzdálenost mezi šablonou a sekvencí chůze, stejně jako nahromaděné náklady na deformaci šablony na části sekvence chůze. Spodní řada matice C je následující:

$$C(1, t) = D(1, t) \quad \forall t \in \{1, \dots, T\}$$

První sloupec je:

$$C(m, 1) = \sum_{i=1}^M D(i, 1) \quad \forall m \in \{1, \dots, M\}$$

Zbývající prvky jsou vypočteny rekurzivně jako

$$C(m, t) = D(m, t) + \min\{C(m-1, t-1), C(m-1, t), C(m, t-1)\} \\ \forall m \in \{1, \dots, M\}, t \in \{1, \dots, T\}$$

- Funkce vzdálenosti D: Horní řada matice C představuje nahromaděné náklady pro zkroucení kroku šablony X na sekvenci Y a lze ji považovat za odpovídající funkci  $\Delta: [1: T] \rightarrow \mathbb{R}$
- Zkreslovací dráha P: Zkreslovací dráha  $P = (p_1, p_2, \dots, p_L)$  délky L s prvky  $p_l$  pro  $l \in \{1, \dots, L\}$  vykazuje dobrou shodu mezi X a Y. Místní minima odpovídající funkce  $\Delta$  jsou považovány za koncové body deformačních cest a počáteční body jsou získány zpětným posunem na matici akumulovaných nákladů. Měla by být zvolena prahová hodnota pro výběr těchto místních minimálních hodnot tak, aby se zjistilo maximální počet příslušných kroků v posloupnosti.
- Hraniční podmínky pro úplný krok:
  - Začátek dráhy deformace P je v horním řádku nákladové matice C.
  - Konec dráhy deformace P je ve spodním řádku nákladové matice C.
  - Podmínka zajištění monotónně klesá dráhy deformace:

$$p_{l+1} - p_l \in \{(1,0), (0,1), (1,1)\} \text{ for } l \in \{1, \dots, L\}$$

Různé varianty metody DTW se liší v nákladové funkci, která se používá k výpočtu matice vzdálenosti D a generování šablon. V této práci použili euklidovské a pravděpodobnostní cenové funkce. Pro generování šablony je zvažována sada kroků libovolné formy a velikosti. Pro eDTW jsou kroky interpolovány na velikost šablony M a jsou zprůměrovány vzorkem podle vzorku pro vytvoření

reprezentativní šablony. V prvním kroku algoritmu DTW se vypočte euklidovská vzdálenost mezi vzorky průměrné šablony  $X$  a sekvence  $Y$  chůze. V případě pDTW je sestaven pravděpodobnostní šablona. Jakmile jsou všechny tréninky zarovnány na stejnou délku  $M$ , vzorový vektor v určitém bodě  $m$  mezi všemi kroky je modelován pomocí Gaussovy distribuce. Výsledkem je, že Gaussové distribuce  $M$  vytvářejí pravděpodobnostní šablonu s délkou  $M$ . Pro zjištění vzdálenosti sekvence chůze k této pravděpodobnostní šabloně vypočítáme pravděpodobnost  $P(y)$  daného vzorku  $y$ , který patří k těmto Gaussovým rozdělením. Tyto pravděpodobnosti poskytují podobnou míru mezi vzorky sekvence  $Y$  chůze a prvky šablony  $X$ . Abychom změnili podobnost na požadovanou vzdálenost  $D(\cdot)$ , Použijeme exponenciální měřítko pravděpodobnosti:


$$D(y) = \exp(-P(y))$$

## Hierarchické skryté Markovy modely (hHMM)

Skryté modely Markov jsou pravděpodobnostní rámce pro sekvenční analýzu dat, které se používají v mnoha aplikačních doménách. V tomto příspěvku používají variaci HMM nazvanou hierarchický HMM (hHMM), který se liší od konvenčních HMM hlavně ve struktuře modelu. V hHMM je možné definovat hierarchii modelových stavů, což je vhodnější pro segmentaci chůze.

Se standardním HMM je reprezentován sled pozorování pomocí pravděpodobnostní distribuce. V této aplikaci jsou data chůze pozorovány. Označme pozorování v čase  $t$  pomocí proměnné  $y_t$ . Předpokládáme, že pozorování v čase  $t$  je generováno nějakým procesem, jehož stavy  $s_t$  jsou skryté. Stavy tohoto skrytého procesu uspokojují vlastnost Markova, což znamená, že vzhledem k hodnotě skrytého stavu  $s_{t-1}$  je aktuální stav  $s_t$  nezávislý na všech stavech před  $t-1$ . Abychom definovali rozložení pravděpodobnosti nad pozorováním, potřebujeme počáteční pravděpodobnost skrytých stavů  $P(s_1)$ , přechodovou matici stavů  $P(s_t | s_{t-1})$  a pozorovací model definující  $P(y_t | s_t)$ . V této práci jsou pozorování modelovány modely Gaussových směsí (GMM).

Z topologického hlediska hHMMs zobecňují HMMs tím, že každý ze skrytých stavů se stává probabilistickým modelem sám o sobě. To znamená, že každý stav je HMM v případě dvouúrovňové hierarchie (viz obrázek č. 1). HMM ve druhé úrovni mají stavy, které jsou označovány jako pod-stavy. Přechody mohou probíhat mezi stavy v jedné úrovni nebo mezi stavy a podstavy v různých úrovních. Nejmenší podstav definuje model pozorování  $P(y_t | s_t)$ .



Obr. č. 1: Topologie dvojstupňového hierarchického skrytého Markovova modelu (hHMM).

Velké kruhy na obrázku č. 1 reprezentují stavy na první úrovni modelu. Každý stav je HMM se pod-stavy (tmavými kruhy). Zde jsme použili HMM vlevo-vpravo na druhé úrovni.



Učení v hHMM vyžaduje odhad parametrů hHMM, včetně přechodových a počátečních pravděpodobností a parametrů GMM založených na daných datech. Po učení modelu můžeme provést závěr, který v naší aplikaci znamená nalezení nejpravděpodobnější posloupnosti stavů  $S$  \* daných pozorovací sekvencí velikosti  $T$ :

$$S^* = \underset{S}{\operatorname{argmax}} P(S1:T|Y1:T)$$

## Sbírání dat a nastavení experimentu

K vyhodnocení metod zahrnovali dva kontrolované a přístrojové testy chůze, které jsou široce používány při vyšetření parkinsonské chůze.

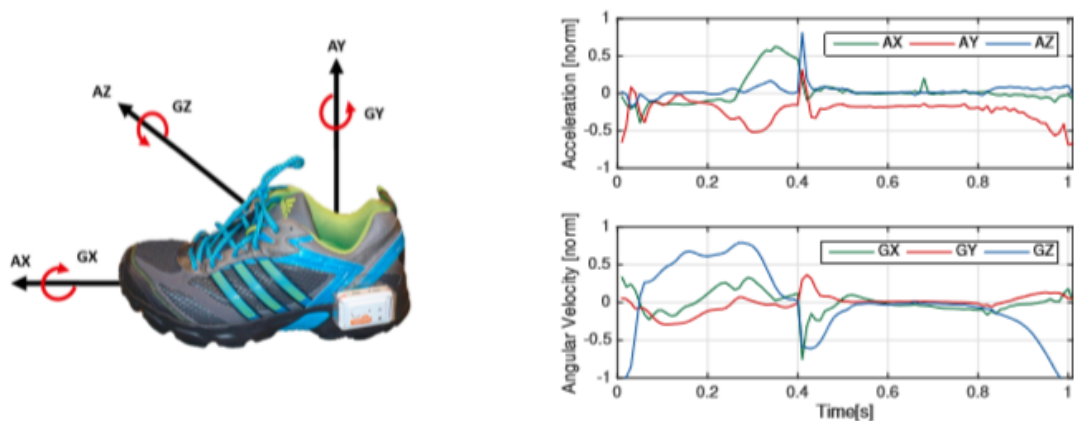
V prvním experimentu byla změřena sekvence kroků z instruovaných přímých procházek od 10 pacientů s PD.

Ve druhém experimentu bylo použito heterogennějšího paradigmatu hodnocení od dalších 34 pacientů s PD, včetně přímých procházek a obrátů, stejně jako pohybů bez použití kroků.

V prvním experimentu bylo zařazeno 10 pacientů s idiopatickým PD ( $63 \pm 9,3$  let, 5 mužů) s motorickým skóre UPDRS  $12,7 \pm 6,0$  a skóre Hoehn a Yahr (H & Y)  $1,7 \pm 0,9$ . Pro tento experiment pacienti chodili čtyřikrát 10 m při samovolné rychlosti. Konečné údaje tedy obsahovaly pouze sekvenci přímých kroků. Pro tento experiment byl celkový počet kroků pro všechny pacienty 496.

V druhém experimentu populace tvořilo 34 pacientů s idiopatickou PD ( $63 \pm 11$  let, 24 mužů). Subjekty se nacházely v časných až středních stupních onemocnění s UPDRS motorickým skóre  $18,8 \pm 8,9$  a skóre H & Y  $2,2 \pm 0,6$ . Celkový počet kroků tohoto experimentu byl 458. Každý pacient provedl TUG test se samostatně-zvolenou rychlostí. TUG test je běžně používaný klinický test pro vyhodnocení rovnováhy a mobility. Pacient se postaví z židle, ujde 3 m, provede otáčku o  $180^\circ$ , vrátí se 3 m a konečně znovu sedí. Test zahrnuje rovnou chůzi a otáčení. V PD je obrát více narušen, než rovná chůze, a proto data z tohoto experimentu mají vyšší intra-pacientovou variabilitu chůze a vedou k heterogennějšímu kroku než první pokus. Přechody mezi sedem-stáním a stáním-sedem dělají segmentaci kroků náročné, protože je nezbytné, aby metody odlišovaly přechodové pohyby od krokových pohybů. Všichni pacienti byli schopni ukončit TUG test bez epizod mrazu nebo dyskinézy. U obou pokusů poskytl pacient písemný souhlas, který byl schválen místním výborem lékařské fakulty na univerzitě v Erlangen v Německu (Re 4208), který následuje po deklaraci Helsinky 1975, revidované v roce 2000.

Pro oba experimenty byla data zaznamenána IMU Shimmer 2R (Shimmer Sensing, Dublin, Irsko), zaznamenávající zrychlení a úhlovou rychlost 102,4 Hz. Každá jednotka sestávala z triaxiálního akcelerometru (rozsah  $\pm 6$  g) a tříosého gyroskopu (rozsah  $\pm 500^\circ / s$ ). Senzorové jednotky byly namontovány bočně na kotník levé a pravé boty pacienta. Měření obou nohou byla zahrnuta do experimentů. Obrázek 2 ukazuje umístění snímače na obuvi a definici os, stejně jako údaje o vzorku pro jeden krok normalizovaný na rozsah snímačů (norma).



Obr. č. 2: (vlevo) Umístění senzoru Shimmer a definice os; (vpravo) Údaje o akcelerometru a gyroskopu pro jeden příkladný krok.

Definování os na obrázku č. 2 AX, AY a AZ tvoří tři rozměry akcelerometru a GX, GY a GZ tvoří tři rozměry gyroskopu.

Cílem posledního experimentu bylo zhodnotit metody v náročných situacích, včetně otáčení a nepohyblivých pohybů. Výsledky ukázaly, že neexistují významné rozdíly mezi metodami prvního scénáře, ve kterých všechny metody dosáhly téměř 100% přesnosti z hlediska F-skóre.

Proto dospěli k závěru, že v případě předem definované a homogenní posloupnosti kroků lze všechny metody použít stejně. V druhém experimentu se však objevil rozdíl mezi metodami, kdy metoda hHMM získala 96 % F-skóre a výrazně převyšoval ostatní metody. HHMM se rovněž ukázala jako slibný při rozlišování mezi kroky a pohyby bez použití kroků, což je kritické pro analýzu klinické chůze.

Výsledky naznačují, že jak přístrojový testovací postup, tak požadovaný algoritmus segmentace musí být vhodně vybrány pro podporu a doplnění klasického klinického vyšetření posuzováním pohybu na základě senzorů.

## 1.2 Detecting freezing of gait with a tri-axial accelerometer in Parkinson's disease patients [2]

Zmrazení chůze (FOG) je běžný motorický příznak Parkinsonovy nemoci (PD), který se projevuje jako neschopnost zahájit nebo pokračovat v chůzi.

Tento článek představuje metodu sledování epizod FOG založených pouze na měřeních zrychlení získaných od zařízení bederního pásu.

### Metody

První je popsán sběr dat, později metodologie a výběr modelu strojového učení (support vector machine (SVM)) a nastíněného přístupu.

### Získávání dat a jejich popisování

Všichni účastníci (ve věku 50 až 75 let) měli klinickou diagnózu idiopatické Parkinsonovy nemoci podle Britské PD Society Brain Bank. Klinické výkyvy byly přítomny u všech pacientů, stejně jako Hoehnova a Yahrůva stadia nad dvěma (středně těžká fáze PD). Dále všichni pacienti před svým podpisem podali svůj podepsaný informovaný souhlas. Experimentální protokol byl schválen příslušnou místní komisí pro etickou revizi. Pro tento příspěvek byly použity signály od 20 pacientů s PD, z nichž 8 pacientů prezentovalo epizody FOG a 12 nezobrazilo symptom. Nahrávky jsou shodné s těmi, které používal Rodríguez-Martín a kol.

Jako součást experimentů byli účastníci zaznamenáni s kamerou HD kvality, když nosili sadu senzorů (tj. Akcelerometr, gyroskop a magnetometr) když prováděli přednastavené scénáře. Nicméně tyto aktivity mají spíše obecnou povahu (např. Procházky kolem bytu nebo nošení plné sklenici vody z kuchyně do jiné místnosti) a jsou mnohem variabilnější ve srovnání s jinými typickými scénáři jako jsou ruka-nos, nebo podobná gesta, které se provádějí v sedící poloze. Nahrávky zahrnují také aktivity, které nebyly napsány během nahrávání, jako například telefonní odpověď nebo podobné neočekávané situace, které v některých případech vedou k epizodám FOG kvůli otřesům nebo procházením úzkých míst. Pokusy probíhaly v bytě účastníka a začaly ráno. Během dne proběhly dvě nahrávací zasedání: jedna v motorovém stavu "OFF" a jedna v motorovém stavu "ON". Na prvním zasedání byli účastníci požádáni, aby vynechali ranní dávku léků, a tak začaly nahrávky, zatímco účastník byl v klinicky definovaném stavu OFF. Po dokončení prvního kola účastníci přijali své obvyklé léky a druhá nahrávka byla zahájena poté, co účastník dosáhl klinicky definovaného stavu ON. Během obou nahrávek účastníci provedli řadu krátkých kontrolovaných aktivit. Činnosti prováděné pacienty v průběhu jejich stavu OFF byly zkouškou chůze v interiéru, provokačním testem FOG a testem chůze. Během stavu ON byl také proveden test dyskineze, test s dvojím úkolem a soubor činností denního života (ADL). ADL zahrnovaly kartáčování zubů, otřásání deodoranty, mazání gumou, psaní tužkou, psaní na klávesnici počítače, čištění okna nebo nábytku a sušení vlhkého skla.

Zkušební lékaři označili videa na základě aktivit, které pacienti provedli, a příznaků, které se objevily během videa. Klinikové, kteří prováděli označení, byli také fyzicky přítomni během nahrávání. Každá z klinických stran (jedna pro každou zemi) měla dva klinické lékaře s několikaletými zkušenostmi s pacienty s PD (tj.  $\geq 5$  let). Před zahájením nahrávání dostali všichni lékaři školení o nastavení

základních údajů pro označení příznaků (včetně FOG). Skupina, která provedla označení, je rozdělena ze skupiny, která provedla analýzu.

Video a inerciální signály byly synchronizovány na základě postupu popsaného v [9]. FOG štítky poskytované klinikami byly ošetřeny automatickým značkovacím postupem, aby byly zvaženy specifické zvláštnosti FOG. V tomto smyslu je důležité poznamenat, že klinici, kteří měli na starosti označení FOG, byli u pacientů během experimentálního protokolu a v důsledku toho tito klinici věděli, zda pacient předložil epizody FOG nebo ne před vyšetřením videozáznamů. Nicméně, v procesu označování pacientů s FOG, mohou klinické chyby některé epizody FOG vzhledem k tomu, že v některých okamžicích, videokamera nebyla dostatečně blízko pozorovat mírné epizody

Nahrávky zamrznutí byly proto řezány až do okamžiku, kdy zůstaly pouze štítky FOG. Tím se snížilo celkové množství údajů o záznamu zamrznutí, ale bylo zajištěno, že nebyly použity žádné epizody zmrazení (které by nebyly správně označeny). Na druhé straně byli pacienti, kteří neměli epizody zmrazení, přejmenováni tak, aby byly použity všechny dostupné údaje. Citlivost byla proto stanovena použitím údajů od pacientů s epizodami zmrazení, zatímco specifická byla stanovena použitím údajů od nemrznoucích pacientů. Celkově tento postup umožnil použití větších částí nahrávek. Pokud jde o skutečné označení, přítomnost jakéhokoli typu zmrazení (např. Start, otočení, konec) byla považována za epizodu FOG. Detekce jednotlivých typů zmrazení vyžaduje další kontextové informace, které nejsou obsaženy v databázi (DB). Navíc taková jemná granularita nemusí poskytovat přídavnou hodnotu (např. PD monitorovací systém). Skutečnost, že se děje epizoda mrznutí, je relevantnější než skutečný typ epizody (např. Pro rytmické účely). Důsledkem toho jsou spíše zmrazené epizody spíše než jednotlivé typy zmrazení.

## Metodologie

Obecná metodika je taková, že signály zrychlení ze senzoru umístěného v pasu jsou rozděleny do stejných oken (tj. Do časových řad je aplikováno posuvné okno). Funkce jsou extrahovány z těchto oken a přiváděny do SVM pro výcvik nebo klasifikaci. Klasifikační výstup  $n$  následujících po sobě následujících oken  $s_1, \dots, s_n$  se pak agreguje v čase  $t$  (v sekundách), aby se dosáhlo vyšší přesnosti. Avšak při vývoji algoritmu pro detekci takových epizod je třeba vzít v úvahu volatilitu FOG. Na rozdíl od klidového tremoru (nebo dyskineze), epizody FOG netrvají po delší dobu, což může zdůraznit význam zvolené velikosti okna  $ws$ . Obsah databáze je v každém případě rozdělen do dvou datových souborů (tj. Školení a testování), které se používají k výcviku SVM a optimalizaci dalších parametrů a testování. Datové sady zůstávají stejné pro všechny přístupy (podrobnosti jsou uvedeny v tabulce 1). Jednotlivé datové soubory obsahují 15 a 5 pacientů pro tréninkový a testovací datový soubor.

Vyhodnocují se dvě sady funkcí: snížená sada funkcí s pouze rychlou Fourierovou transformací (FFT) a sadu funkcí s různými doplňkovými funkcemi (viz tabulka 2). Účinek přidání těchto dalších vlastností je kvantifikován v sekci. 3. Tyto funkce se skládají z indexu zmrazení a některých funkcí týkajících se frekvence pro různé frekvenční rozsahy.

Tab. č. 1: Počet oken (před agregací) v každé sadě dat, které se používají pro označení FOG

	<i>Trénink</i>	<i>Test</i>
<i>Počet mrazících oken</i>	93	45
<i>Počet nemrazících oken</i>	3883	2312
<i>Záznamy se zamrznutím</i>	6	2
<i>Záznamy bez zamrznutí</i>	9	3
<i>Celkový počet pacientů</i>	15	5
<i>Průměrná doba záznamů s mrazem (min)</i>	1838	24.32
<i>Průměrná doba záznamů bez mrazu (min)</i>	9.59	19.48

Tab. č. 2: Plná sada funkcí používaných pro detekci FOG. Naproti tomu redukovaná sada funkcí zahrnuje pouze rychlou Fourierovu transformaci (tj. Index 1)

Index	Funkce
1	<i>FFT (bez filtrů, drsná)</i>
2	<i>Střední a standardní odchylka amplitudy (pásmo: 0,5-3,0 Hz)</i>
3	<i>Entropie signálu v časové oblasti (pásmo: 0,5-3,0 Hz)</i>
4	<i>Amplituda vrcholu a její frekvence (pásmo: 0,5-3,0 Hz)</i>
5	<i>Průměrná a směrodatná odchylka amplitudy (pásmo 3,0 až 8,0 Hz)</i>
6	<i>Entropie signálu v časové oblasti (pásmo 3,0 až 8,0 Hz)</i>
7	<i>Amplituda špičky a její frekvence (pásmo 3,0 až 8,0 Hz)</i>
8	<i>Index mrazu</i>

Nejprve byly vyhodnoceny různé velikosti oken s hodnotami tak, aby bylo optimalizováno zamrznutí detekce chůze. Porovnání různých velikostí oken bylo provedeno na úrovni epizod (spíše než na úrovni okna). Epizoda FOG byla zjištěna, když bylo alespoň jedno okno v rámci skutečné epizody FOG klasifikováno jako takové. Pokud jde o nemrzoucí epizody, provádí se agregace oken po dobu, která odpovídá průměrné délce epizody FOG plus dvojnásobek standardní odchylky. Data zrychlení byla pře vzorkována na 40 Hz a rozdělena do neizolovaných kusů dat s1, ..., sm s určitou délkou ws,

kteřá se překřývají na 50 %. Tato okna se pak používají k získání prvků, které byly následně přiváděny do SVM pro výcvik a klasifikaci. To se podobá prvnímu a naivnímu přístupu, kde zmrazení 1 představuje okno v sérii  $s_1$ , zda je v tomto okně přítomno FOG.

$$freezing_j^1 = \begin{cases} 0 \text{ no freezing} & \text{if } f_{SVM} \leq 0 \\ 1 \text{ freezing} & \text{if } f_{SVM} > 0 \end{cases}$$

kde  $f_{SVM} = \sum_{i=1}^l y_i \alpha_i K(x_o, f) + b$ ,  $x_i, \dots, x_l$  jsou podporující vektory (SVs) pro SVM,  $y_i, \alpha_i$  jsou odpovídající označení a Lagrangeův násobek každého SV a  $b$  je předpojatost. Číslo v horním indexu (zde: 1) označuje variace. Druhá a třetí varianta použijí 2 a 3, resp. Druhá variace agreguje výstupy SVM v časovém období  $t$  a vypočítává stupeň spolehlivosti  $c_j$ . Pokud hodnota spolehlivosti přesahuje prahovou hodnotu  $th$ , agregovaný časový rámec  $t$  se považuje za epizodu FOG, jinak ne. Zde zmrazení 2j pokrývá časový rámec  $t$  (začíná v okně  $j$ th a pokrývá  $n$  okna) a určuje, zda je FOG v daném časovém rámci zřejmý.

$$t = ws(n + 1) / 40 * 2$$

$$c_j = \sum_{i=j}^{j+n-1} \frac{freezing_j^1}{n}$$

$$freezing_j^2 = \begin{cases} 0 \text{ no freezing} & \text{if } c_j < th \\ 1 \text{ freezing} & \text{if } c_j \geq th \end{cases}$$

Kde  $c_j, th \in [0,1]; n, j \in N; n, j > 0; t \in R+$ .  $n$ , jak již bylo popsáno, odpovídá počtu oken, které jsou agregovány za účelem prodloužení časové periody  $t$  sekund.

Třetí změna zavádí druhou prahovou hodnotu. Dolní prah  $th_l$  a horní prah  $th_u$  lze použít k naladění citlivosti a specificity zvlášť. Dolní prahová hodnota  $th_l$  nastavuje maximální hodnotu spolehlivosti pro období "freezing" a horní prah  $th_u$  nastavuje minimální hodnotu spolehlivosti pro zmrazené epizody. Nepožaduje-li, aby tyto prahové hodnoty byly stejné (což by v podstatě znamenalo dvě varianty), konečný výstup algoritmu může znamenat přítomnost zmrazení, stejně jako "nedefinované". To je případ, kdy hodnota spolehlivosti je mezi dvěma prahové hodnoty. V důsledku toho mohou být některá souhrnná okna ignorována a snížena spotřeba dat.

$$freezing_j^3 = \begin{cases} 0 \text{ no freezing} & \text{if } c_j < th_l \\ 1 \text{ freezing} & \text{if } c_j \geq th_u \\ -1 \text{ undefined} & \text{if } th_l \leq c_j < th_u \end{cases}$$

$$\text{kde } c_j, th_l, th_u \in [0,1]; th_l \leq th_u; j \in N; j > 0$$

Jsou testovány tři aproximace této metody. Zpočátku je FOG přímo detekován podporou vektorového stroje (SVM). Potom se výstupy klasifikátoru shromažďují v průběhu času, aby se stanovila hodnota spolehlivosti, která se používá pro konečnou klasifikaci zmrazení (tj. Druhý a třetí přístup).

## Výběr modelu

Jednotlivé modely SVM jsou natrénovány s funkcemi, které byly získány z tréninku. Pro druhou a třetí variantu jsou jednotlivé parametry  $t$ ,  $th$ ,  $th_l$  a  $th_u$  optimalizovány také v souboru tréninkových dat. Konečné výsledky jsou získány z testovací datové sady. Velikost okna  $ws$  je určena před vyhodnocením některého z těchto parametrů. Pro každou z navržených velikostí oken  $ws$  (viz níže) se

použije naivní algoritmus na soubor tréninkových dat. Velikost okna, která dosahuje nejlepší kombinace přesnosti a geometrického průměru, je zvolena.

Během tréninku byla brána v úvahu různá nastavení pro jádro, váha, náklady a gamma. Váhové parametry byly použity k vyvážení obou tříd "FOG" a "nemrznoucí". Hodnoty nákladů a gama byly systematicky vyhodnocovány (tj.  $10q$ ,  $q \in \{-3, -2, \dots, 2, 3\}$ ) v závislosti na zvoleném jádře (tj. jádro radiální základové funkce (RBF) nebo lineární jádro). Navíc je na souboru tréninkových dat provedeno desetinasobné křížové ověření. Namísto zprůměrování přesnosti tréninku se však použije geometrický průměr citlivosti a specifčnosti (tj.  $\sqrt{(Citlivost * specifčnost)}$ ) pro identifikaci těch kombinací parametrů s vysokou citlivostí a specifčností. Maximální geometrický průměr se používá k výběru optimálních parametrů a získání konečného modelu SVM, který se má použít s testovacím datovým souborem. Geometrický průměr byl zvolen tak, že se jedná o obě třídy stejně jako o přesnost, která implicitně váží třídy. Vážení posledně zmíněného opatření může být problémem, pokud mají třídy (velmi) odlišné priority.

Byly vyhodnoceny následující diskrétní hodnoty:  $ws \in 2^{\{5,6,7,8\}}$ ;  $t \in \{10,15,20,25,30,45,60\}$ ;  $th, th_l \in \{0,0,0,0,0,1, \dots, 0,95,1,0\}$ ;  $th_u \in (th_u \geq th_l \mid th_u \in \{0,0,05,0,1, \dots, 0,95,1\})$ . Příslušné hodnoty a parametry byly vyhodnoceny pro každou ze čtyř podmínek (dvě jádra a dvě sady funkcí).

## Výsledky

Všechny varianty jsou natrénovány signály 15 pacientů a vyhodnoceny signály od dalších 5 pacientů. Pomocí lineárního SVM jádra poskytuje třetí přístup 98,7 % přesnost a geometrický průměr 96,1 %.

Dále se zkoumá, zda jsou frekvenční charakteristiky dostatečně spolehlivé pro zjištění FOG. Výsledky ukazují, že tyto funkce umožňují detekovat FOG s přesností přes 90 % a že frekvenční charakteristiky umožňují spolehlivé monitorování FOG pomocí jednoduchého bederního pásu s inerciálními senzory.

### 1.3 Feedforward Neural Network for Time Series Anomaly Detection [10]

Detekce anomálií v čase je často formulována, jako hledání určitých dat vzhledem k datům standartním. K zajištění stabilní a efektivní práci systému je potřeba, aby se monitorovali obrovské množství dat, kterým se říká Klíčové funkční indikátory. Například internetové společnosti monitorují úspěšnost přihlášení k nějaké stránce, nebo její návštěvnost během dne. Tyto dvě série dat mají rozdílné klíčové funkční indikátory a z tohoto důvodu se k nim nedá využít jednoduchý statistický model k detekování anomálií. Z tohoto důvodu se zde aplikují neuronové sítě.

Detekce anomálií je aktivním studiem v oblasti strojového učení a statistiky. Statistické metody pro detekci anomálií v časovém modelu jsou např. ARIMA a sezónní ARIMA modely [11],[12], Holtův-Wintersův model [13]. Oproti tomu ve strojovém učení jsou metody na detekci anomálií např. učení s učitelem a učení bez učitele.

Hluboká dopředná neuronová síť je síť jednosměrná. Znamená to tedy, že může být trénovaná z tzv. hrubých dat.

Výstup skrytých vrstev natrénované neuronové sítě může být brán jako jednotlivé hledané vlastnosti série dat.

Anomálie v datech jsou data s nečekanými vlivy na průběh dat. Tyto anomálie znamenají, že některé systémy nefungují dostatečně správně, např. se někteří uživatelé nedokážou přihlásit na webové stránky atd.

Ve strojovém učení jsou dva důležité ukazatele přesnosti natrénovaného modelu. Jsou jimi odvolání a preciznost neboli recall and precision. Při detekci anomálií se používá záporné označení k naznačení případu anomálie a pozitivní označení k naznačení normálního průběhu dat, poté může být model odvolání a preciznosti definován jako:

$$\text{odvolání} = \frac{\text{počet detekovaných skutečných anomálií}}{\text{počet skutečných anomálií}}, \text{neboli}$$

$$\text{odvolání} = \frac{TN}{TN + \neg FP}$$

$$\text{preciznost} = \frac{\text{počet detekovaných skutečných anomálií}}{\text{počet detekovaných anomálií}}, \text{neboli}$$

$$\text{preciznost} = \frac{TN}{TN + \neg FN}$$

, kde TP, FN, FP a TN znamenají: TP= skutečné pozitivní hodnoty, FN= falešné negativní hodnoty, FP= falešné pozitivní hodnoty a TN= skutečné negativní hodnoty. Krom preciznosti a odvolání existuje ještě F1-míra, F1-míra je obsáhlá hodnota měření výkonu modelu strojového učení a je definována takto:

$$F1 - \text{míra} = \frac{2 * \text{preciznost} * \text{odvolání}}{\text{preciznost} + \text{odvolání}}$$



K vytvoření modelu detekování anomálií v sérii dat je potřeba vytvořit model strojového učení, jenž bude mít hodnoty odvolání a preciznosti co nejvyšší.

Tab. č. 3: Matice záměn


SKUTEČNÉ VÝSLEDKY	PŘEDPOVĚZENÉ VÝSLEDKY	
	POZITIVNÍ	NEGATIVNÍ
POZITIVNÍ	TP	FN
NEGATIVNÍ	FP	TN

### Problémy v detekci anomálií v sérii dat

- Velké množství dat v datové sérii.
- Problém s nevyvážeností třídy. V reálném světě je mnohem větší množství dat v normálních datech a malé množství v abnormálních datech. Nastává zde problém nevyvážených školicích údajů.


### Návrh systému

Návrh systému detekce anomálií v obrázku č. (). Systém se liší od ostatních neuronových sítí tím, že není potřeba připravit indikátory tzv. features, pro správnou funkčnost detekce anomálií. Využitím hluboké dopředné neuronové sítě jsou získány všechny vlastnosti indikátorů časové řady. Trénování je prováděno na tzv. hrubých datech a jejich indikátorech. Poté jsou výstupy časových řad brány jako indikátory anomálií časových řad.



Obr. č. 3: Návrh systému neuronové sítě.

Dopředná neuronová síť je složená ze vstupní vrstvy, poté dvěma skrytými vrstvami neuronů a výstupní vrstvou, jak je znázorněno na obrázku č. 4.



Obr. č. 4: Architektura hluboké dopředné neuronové sítě.

Dříve byl zmíněn problém s nevyváženými daty, kdy data normální vysoce převažují data abnormální. Nevyvážení dat se řeší dvěma způsoby a to tzv. under sampling a over sampling dat. V této práci byl vybrán under sampling pro výběr všech abnormálních dat a pouze dvojnásobku normálních dat, pro vytvoření poměru 2:1. Pro správné naučení neuronové sítě je potřeba využít alespoň 100 tisíc vzorků.

## Výsledek

Trénování hluboké dopředné neuronové sítě potřebuje pouze hrubé data a označené anomálie dat. Důležitým výsledkem je fakt, že není potřeba ke správnosti výsledných dat využít předzpracování před trénováním neuronové sítě. Výsledné hodnoty skrytých neuronových sítí jsou tedy indikátory abnormalit dat. Systém hluboké dopředné neuronové sítě pracuje s přesností F1-skóre 87.6 %.

## 2. TEORETICKÝ ROZBOR

### 2.1 Parkinsonova nemoc

*„Parkinsonova nemoc (PN) je chronické progresivní onemocnění nervové soustavy, projevující se typickou poruchou hybnosti, tzv. extrapyramidovým hypokineticko-rigidním syndromem. Toto postižení vzniká na podkladě degenerativního zániku neuronů v substantia nigra, vedoucího k nedostatku dopaminu ve striatu. Poruchu hybnosti u PN proto charakteristicky zmírňuje dopaminergní substituční terapie.“ [3]*

### 2.2 Historie

Poprvé toto onemocnění popsal anglický lékař James Parkinson v roce 1817 ve své knize „An Essay on the Shaking Palsy“. V této publikaci je popsáno 6 případů onemocnění projevujících se třesem, pohybovou chudostí, svalovou ztuhlostí, poruchou chůze a stoje. Příznaky Parkinsonovy nemoci byly již popsány mnohem dříve například v indických eposech (2500 př. n.l.), v Galénových záznamech nebo v dílech Leonarda da Vinciho. James Parkinson je, ale první popsal jako samostatnou klinickou jednotku. Charcot a Growers doplnili popis nemoci a pojmenovali ji po jejím objeviteli, dříve byla známa jako třaslavá obrna. [3]

Pokusy o léčbu Parkinsonovi nemoci se objevují v druhé polovině 19. stol., jednalo se o přípravek rostlinného původu s anticholinergním účinkem pod názvem Belladonna. Prvními synteticky vyrobenými léky byla anticholinergika, která tlumila třes. [3]

O zásadní průlom v léčbě se zasloužil farmakolog a biochemik Carlsson, který v roce 1958 zjistil, že se v oblasti bazálních ganglií vyskytuje velké množství dopaminu. Následné objevy prokázaly, že Parkinsonovu nemoc způsobuje nedostatek dopaminu v substantia nigra. V roce 1961 byla poprvé úspěšně použita k léčbě levodopa (L-DOPA), základní výrobní kámen dopaminu. V 60. letech 20. stol. byly objeveny benserazid a karbidopa, které potlačují vedlejší účinky levodopy, kombinace těchto léčiv se používá dodnes a žádný jiný lék jejich účinnost zatím nepřekonal. [3]

### 2.3 Anatomie a fyziologie

#### Extrapyramidový systém

Extrapyramidový systém je tvořen bazálními ganglii – nucleus caudatus, lentiformis a corpus Luysi, bazální ganglia jsou uložena v koncovém mozku (telencephalon). Nucleus lentiformis se skládá z putamen a globus pallidus. Nucleus caudatus a putamen tvoří striatum. Z kmenových struktur k systému patří nucleus ruber, substantia nigra a částečně i retikulární formace uložené ve středním mozku (mesencephalon). [3]

Hlavní dráha extrapyramidového systému vede z thalamu do striata, ze striata do palida odtud vede největší odstředivá dráha bazálních ganglií do nucleus ruber, thalamu, substantia nigra a retikulární formace. Extrapyramidový systém reguluje svalový tonus a zabezpečuje základní posturální, hybné mechanismy a pohybové automatismy. Podílí se i na koordinaci volní hybnosti a na iniciaci pohybů, protože k aktivaci systému dochází ještě před začátkem pohybu. [3]

## **Fyziologie bazálních ganglií**

Koordinační pohybové působení BG je umožněno zapojením do sítě spojů, uplatňuje se zde řada neuromediátorů a neuromodulátorů. Synapse (spoje) jsou tvořeny presynaptickým a postsynaptickým neuronem, které jsou excitovány nebo inhibovány neuromediátory. Na presynaptické části neuronu jsou vezikuly s obsahem neuromediátoru, ten se po podráždění uvolní do synaptické štěrbině. Bílkoviny na postsynaptickém neuronu rozpoznají neuromediátor a zprostředkují buněčnou reakci. [3]

## **Epidemiologie**

Výsledky epidemiologických zkoumání PN se musí brát velmi opatrně, protože jejich výsledek může být ovlivněn mnoha faktory. S tímto problémem se setkáváme především v určení správné diagnózy, kde ve 20% dochází ke stanovení falešné diagnózy, kdy je omylem diagnostikována PN u jiné choroby nebo je PN brána jako jiné onemocnění. Dále se většina výzkumů provádí pouze v určitých oblastech, ne velkoplošně apod. [3]

## **Prevalence a incidence**

Zdroje uvádějí prevalenci 84 – 187 nemocných na 100 000 obyvatel, z toho plyne, že s PN je léčen každý tisící člověk v Evropě. U osob starších 60 let prevalence stoupá na 1 nemocného na 100 obyvatel. V roce 2007 bylo v České republice přibližně 10 000 – 15 000 15 osob s Parkinsonovou nemocí. [3, 6]

Incidence nemoci za 1 rok je 5 – 24 pacientů na 100 000 obyvatel. Průměrný věk při stanovení diagnózy je okolo 50 - 60 let. Před 40. rokem věku onemocní 10% pacientů, stejně tak po 75. roce věku. V posledních 50ti letech se počet onemocnění zvyšuje, někteří autoři to zdůvodňují dožíváním se vyššího věku, zlepšováním diagnostiky a terapie, lepšími znalostmi symptomů onemocnění. [3, 6]

PN postihuje o málo častěji muže než ženy v poměru 1,2:1. Některé studie udávají vyšší výskyt nemoci u Indoevropanů než u Afričanů a Asiatů. Prokázán je i vyšší výskyt v zemědělských oblastech než v oblastech průmyslových, příčinou by mohly být herbicidy. [3, 6]

Mortalitu zdroje udávají 0,5 – 3,8 případů na 100 000 obyvatel, příčinou nebývá sama o sobě nemoc, ale její komplikace např. pády. Po zavedení léčby levodopou se doba přežití zvýšila o 13–14 let. [3]

## **Etiologie**

Příčina vzniku Parkinsonovi nemoci není doposud známa. Existují tři hypotézy, které by mohly mít vliv na její vznik. [3]

Onemocnění vzniká po neuronální ztrátě v pars compacta substantiae nigrae, kdy klesá syntéza dopaminu v této oblasti. Jedná se o dynamický proces rozvoje patologických změn a klinický obraz nemoci se s největší pravděpodobností projevuje po delším subklinickém období. Toto období se odhaduje na 3–5 let a nazývá se preklinické (asymptomatické) stadium dopaminového nigrostriatového deficitu. První klinické projevy nemoci se objevují, když klesne původní množství syntézy dopaminu pod 20 %. [3]

Zdroje uvádějí některé možnosti, jak se pokles dopaminu v substantia nigra rozvíjí:

- množství dopaminu je nižší od narození a procesem fyziologického stárnutí klesá pod 20 %, což ukazuje na genetickou poruchu;
- endotoxiny nebo exotoxiny jednorázově poškodí dopaminergní buňky nebo schopnost syntézy dopaminu a následuje úbytek buněk v důsledku stárnutí; 16
- zvýšená ztráta schopnosti syntézy dopaminu nebo zvýšená buněčná smrt se rozvíjí již od narození, příčinou by mohla být genetická porucha;
- endotoxiny či exotoxiny způsobí neschopnost syntézy dopaminu nebo zvýšenou buněčnou smrt v průběhu života.

## **Endotoxiny**

Mozek má vyvinuty detoxikační mechanismy, díky nim je schopen se bránit některým škodlivým látkám. Endotoxické poškození vzniká, pokud se toxiny vytvářejí v nadměrném množství a detoxikační mechanismy nepostačují. Druhou možností je fyziologické množství toxinů, ale poškozené detoxikační mechanismy. [3]

Hlavním endotoxinem v této oblasti jsou volné radikály kyslíku. Ty se tvoří během degradace dopaminu pomocí enzymu monoaminoxidázy typu B (MAO-B). Volné radikály jsou nestabilní, vysoce reaktivní a ve vyšším množství poškozují buněčné lipidy, proteiny a DNA. Dochází zde ke zvýšené lipoperoxidaci, zvýšenému množství železa, snížení množství protektivních enzymů a snížení mitochondriálního komplexu I. [3]

## **Exotoxiny**

Exotoxin, který vyvolává příznaky PN se nazývá 1-metyl-4-fenyl-1,2,3,6- tetrahydropyridin (MPTP). Účinky této látky byly objeveny náhodně v USA skupinou toxikomanů, vzniká jako vedlejší produkt při výrobě heroínu a vyvolává stejné příznaky jako PN. MPTP se za pomoci MAO-B přeměňuje na toxickou látku MPP+, která neobjasněným způsobem proniká do mitochondrií a naruší funkci mitochondriálního komplexu I, tím způsobí neuronální smrt. [3]

MPTP je v malém množství obsažen i v některých průmyslových zplodinách, herbicidech a pesticidech. [3]

## **Apoptóza**

V substantia nigra dochází u PN k apoptóze neboli buněčné smrti. V současnosti je intenzivně zkoumána v souvislosti se vznikem Parkinsonovy nemoci, je možné, že popsané etiologické faktory mohou být pouze sekundárními projevy, ne původci nemoci. [3]

## **Patofyziologie**

Hlavním patogenetickým dějem PN je neurodegenerativní postižení pigmentových buněk pars compacta v substantia nigra a následný nedostatek dopaminu ve striatu. [3]

U lidí postižených PN nalézáme depigmentaci jader v substantia nigra a locus coeruleus, úbytek neuronů, gliózu a Lewyho tělíska (cytoplazmatické inkluze). Lewyho tělíska jsou 18 popisována jako

acidofilní kulovité nitrobuněčné inkluze, velké 3–25  $\mu\text{m}$ , s hutným amorfním jádrem z hyalinního materiálu a bledším vláknitým okrajem – halo. Nález těchto tělísek v substantia nigra a locus coeruleus potvrzuje diagnózu Parkinsonovy nemoci, můžeme je však prokázat v centrálním nebo periferním nervstvu i u jiných nemocí např. u Alzheimerovy nemoci. [3]

Hybné příznaky nemoci jsou následkem úbytku neuronů v substantia nigra. Vegetativní a psychické poruchy se projevují při úbytku neuronů v locus coeruleus, nucleus dorsalis n. vagi a nucleus basalis Meynerti. [3]

## **Klinický obraz**

Preklinické období nemoci trvá několik let. V tomto období se projevují nespecifické příznaky, mezi ně patří bolesti ramen a zad, pocity tíže končetin, ztráta výkonnosti, únavový syndrom, poruchy spánku, obtíže, tichost a monotónnost hlasu, zhoršení písma, deprese a snížení sexuální výkonnosti. Tyto projevy jsou součástí mnoha onemocnění, proto v tomto stádiu bývá až v 50 % mylně stanovena diagnóza. [3, 5, 6]

Třes, svalová ztuhlost, zpomalení pohybů, problémy se započítáním pohybu, zmenšený rozsah pohybu, porucha stoje a chůze jsou hlavní příznaky nemoci a projevují se měsíce i roky po nespecifických příznacích. Hlavní příznaky se objevují ve 3. – 4. stadiu nemoci. [3, 5, 6]

## **Tremor (třes)**

Tremor je mimovolní, rytmický a kontinuální svalový pohyb o periodických oscilacích. Třes u PN se objevuje zejména v klidu, je asymetrický, pravidelný, s maximem projevu na akru končetiny a pomalé frekvence 4–7 kmitů za sekundu. [3, 5, 6]

Třes se zvyšuje, když pacient pohybuje druhou končetinou nebo při chůzi. Během pohybu postiženou končetinou tremor ustupuje. Třes začíná na distální části jedné končetiny může se projevit i na jednom prstu nebo plosce nohy a postupuje proximálně, poté přechází na druhou zpravidla stejnostrannou končetinu. Na postižené ruce lze pozorovat addukčně flexní pohyb 20 palce oproti ostatním prstům, který vypadá jako při počítání peněz. Třes se může vyskytovat i na trupu. Třes hlavy se neobjevuje ani v pokročilých stádiích PN, může být přítomen pouze třes brady. [3, 5, 6]

Frekvence třesu na jednotlivých končetinách může být rozdílná, ale je stabilní. Amplituda tremoru se v pokročilejších stádiích zvyšuje. Amplituda třesu je závislá na únavě, na emočním prožívání pacienta, při stresu se amplituda zvyšuje. Během spánku nemusí být třes vůbec patrný. [3, 5, 6]

## **Rigidita (svalová ztuhlost)**

Rigidita znamená zvýšený svalový tonus, který se projevuje konstantně v celém rozsahu aktivně a pasivně prováděného pohybu jako zvýšená, plastická rezistence. [3, 5, 6]

Svalová ztuhlost je patrná od samotného začátku onemocnění především v axiálním svalstvu, i když si ji pacienti většinou neuvědomují. Zasahuje především flexorové svalstvo, což má za následek flexní držení šíje, trupu a končetin. [3, 5, 6]

V pokročilém stádiu popisují pacienti pocit, že jim tělo klade při pohybu odpor, popisují je jako kdyby se pohybovali v hluboké vodě. Rigidita se v pozdějších stádiích projevuje i na mezižebních svalech, což s bradykinézi a hypokinézi způsobuje omezení dýchacích svalů. [3, 5, 6]

## **Bradykineze (pohybové zpomalení), hypokineze (zmenšení rozsahu pohybů), akineze (neschopnost započít pohyb), dyskineze (mimovolní pohyby)**

Bradykineze, hypokineze, akineze jsou typické symptomy postižení bazálních ganglií. Stejně jako tremor a rigidita se tyto symptomy objevují asymetricky, šíří se od akrálních částí proximálně a také je ovlivňuje psychika pacienta. [3, 5, 6]

Jemná motorika je zpomalená a nevýkonná, to ovlivňuje denní činnosti jako oblékání, zapínání malých knoflíčků, navlékání ponožek, zavazování tkaniček, čištění zubů. Při psaní se zmenšuje písmo, ke konci řádku jsou písmena tak malá, že je obtížné, je přečíst (mikrografie). Pacienti mají tichý a monotónní hlas. Snižuje se mimika obličeje, mají otupělý a maskovitý výraz. [3, 5, 6]

Zpomaluje se tempo při chůzi, zkracuje krok. Pacienti šoupají podrážkami bot o podlahu. Snižují se souhyby horních končetin při chůzi. Nemocným dělá obtíže zvednout se ze židle. Po ulehnutí na lůžku je obtížné položit hlavu na polštář, proto hlava zůstává pár centimetrů nad ním. [3, 5, 6]

Každý pohyb znamená pro nemocného velké úsilí a soustředěnost, největším problémem je samotné započítí pohybu. I malá zátěž je unaví. Může se stát, že pacient nedokáže dokončit pohyb a ustrne v jedné poloze. V noci jim dělá obtíže dojít si na WC nebo se otočit v lůžku. Snižuje se i pohyb hrudníku, což může mít za následek hypooxygenaci a hypostatickou pneumonii. [3, 5, 6]

Akineze se objevuje především u prvního kroku, při pohybu v úzkém prostoru. Tyto obtíže se dají zmírnit rytmičnými povely, pravidelnými obrazci na podlaze, přesunutím těžiště na druhou končetinu. [3, 5, 6]

Dyskineze se vyskytují především v pokročilém stádiu PN, jsou to tzv. polékové dyskineze. Patří mezi ně dystonie (porucha svalového napětí), semiflexní držení trupu a končetin. Myoklonus (krátké svalové záškuby) je častou příčinou poruch spánku. Akatize (záchvatovitý svalový neklid) objevuje se přes den nebo v noci bývá spojený s úzkostí. U pacientů v klidu lze pozorovat syndrom neklidných nohou, který se projevuje jemnými dysestéziemi a parestéziemi lýtek, chodidel a prstů, nutící k pohybu, při pohybu přechodně mizí. [3, 5, 6]

## **Posturální nestabilita, porucha chůze**

Poruchy rovnováhy a chůze se objevují v pokročilých stádiích, společně s bradykinezí, hypokinezí a akinezí vedou ke snižování soběstačnosti pacienta. Tyto obtíže jsou důsledkem poruchy vzpřimovacích reflexů, posturálních reakcí, ochranných reakcí bránících pádu, vestibulární dysfunkce, rigidity, bradykineze, hypokineze a akineze. [3, 5, 6]

U nemocných s Parkinsonovou nemocí pozorujeme charakteristické držení těla. Trup a šíje jsou ve flexi, v pokročilém stádiu jsou flektovány i horní a dolní končetiny. Zápěstí a metakarpofalangeální klouby jsou flektovány, interfalangeální klouby bývají v hyperextenzi a poslední skloubení prstů je opět ve flexi. Podobné postižení je i na dolních končetinách, pouze palec zde nacházíme hyperextendován. [3, 5]

Pravděpodobně na podkladě hypokineze dochází ke ztrátě synkineze, neboli ke ztrátě souhybů horních končetin při chůzi. Parkinsonici chodí krátkým, šouravým krokem, mají obtíže se započítím pohybu tzv. hesitace, kdy přešlapují na místě a nemůžou vykročit nebo se před překážkou náhle zastaví

tzv. freezing. Pacient zarazí pohyb před překážkou nebo v zúženém prostoru a dělá mu obtíže pokračovat v cestě. Otáčení je pomalé a nejisté. V klidu nebo při pohybu dochází k tzv. pulzím, což je tendence k pádu bez poruchy vědomí nebo vertiga. Kolísá rychlost chůze (festinace). [3]

### **Hypomimie (snížená mimika obličeje)**

Hypomimii lze pozorovat již v časných stádiích onemocnění. Postupně se snižuje rozsah mimického svalstva obličeje např. při smíchu, pláči. Výraz obličeje se v závislosti na 23 psychickém prožívání mění pomaleji. Snižuje se frekvence mrkání, bývá přítomen Cowperův příznak (retrakce horního víčka). V pokročilejších stádiích je tzv. maskovitý obličej, na kterém nelze poznat žádný emocionální prožitek. Pacient má stále stejný výraz, na okolí působí apaticky. [3]

### **Dysartrie, hypofonie**

Snížení hlasitosti a monotónnost projevu se objevují již v časných stádiích. Občas se u nemocných objevuje zrychlený tok mumlavé řeči, které vede k nesrozumitelnosti. Na začátku věty může docházet k hesitaci, ke konci věty se rychlost řeči zpomaluje. Někdy se opakují poslední slova nebo věty. Porucha řeči a hlasu může vést ke konfliktům. [3]

V terminálním stádiu může tato porucha přejít v afonii a anartrii.

### **Vegetativní dysfunkce**

Nejčastějším problémem nemocných s PN je obstrukce. Někdy bývá mylně spojována s léčbou L-DOPA nebo anticholinergiky. K léčbě zácpy se využívají laxancia, klyzmata a digitální vybavení stolice. K inkontinenci moče a stolice zpravidla nedochází. U mužů může docházet k opožděnému startu mikce, polakisurii, retenci moče. Obtíže jsou důsledkem hypertrofie prostaty a užívání anticholinergik. Výjimkou nejsou ani sexuální poruchy. [3]

Porucha polykání se vyskytuje zřídka a je následkem anteflexního držení hlavy a šíje při stolování. Dochází k nadměrnému tvoření slin, problém je však v poruše polykání slin. [3]

V obličeji a ve kšticí dochází ke zvýšené tvorbě mazu. Pacienti se více potí, hlavně v nočních hodinách.

Pacienti s PN často trpí poruchami spánku. Problémy dělá usínání a časté probouzení z důvodu špatného psychického stavu a častým drážděním močového měchýře. Po probuzení mají pacienti větší problémy s pohybem.

### **Psychické poruchy**

Nejčastěji se u pacientů s Parkinsonovou nemocí objevují deprese. Deprese jsou způsobené nedostatkem dopaminu, serotoninu a noradrenalinu v mozku. Pacienti prožívají pocity beznaděje, úzkosti, podceňují se. Deprese se může projevit celkovou skleslostí, nadměrnou únavou, poruchou spánku nebo poruchou příjmu potravy. Tyto pocity mohou vést k pokusům o sebevraždu nebo k dokonané sebevraždě. Deprese nebývá vyvolána příznaky onemocnění, ale způsobuje ji poškození transmitterové a receptorové rovnováhy. [3]

V pozdních stádiích onemocnění se může projevovat demence, která způsobí nesoběstačnost pacienta v běžných denních aktivitách, zapomínají, bloudí, někdy se objevuje zmatenost. [3]



U některých pacientů jsou jen omezeny některé duševní funkce např. orientace v prostoru, porucha paměti.

## **2.4 Vyšetřovací metody**

### **Základní screening**

Základní screening provádí již praktický lékař, při podezření na rozvoj Parkinsonovy nemoci. Lékař klade pacientovi 9 otázek, pokud na 5 a více pacient odpoví kladně, je podezření na PN opodstatněné. [3, 6]

### **Anamnéza**

Pacienta se ptáme na hlavní příznaky onemocnění hypokineze – rigidita – klidový třes. Zjišťujeme, jak se nemoc rozvíjí, měla by být bez náhlých zvratů. Ptáme se na psychické a vegetativní poruchy, které nemocný mnohdy nedává do souvislosti s onemocněním. Pokud již byla provedena léčba levodopou, je třeba zjistit, zda došlo ke zlepšení hybných obtíží a jaká dávka byla podána. [3, 6]

Aktivně pátráme po prodělaných nemocech, jako je deprese, endokrinopatie, metabolické poruchy aj. Zajímá nás práce v rizikovém prostředí (mangan, oxid uhelnatý, sirouhlík, insekticidy), užívání neuroleptik. V rodinné anamnéze pátráme po podobných příznacích, které by potvrdily nebo vyloučily diagnózu PN. [3,6]

### **Vyšetřovací schéma a škály hodnotící tíži onemocnění**

Nemocného vyšetřujeme neurologicky, dále se zaměřujeme na hlavní motorické příznaky nemoci, změny nálady a kognitivní funkce. [3]

### **Jednotná stupnice pro hodnocení Parkinsonovy nemoci (UPDRS)**

UPDRS je v dnešní době nejčastěji používanou škálou pro vyšetření motorických a non-motorických projevů. Pomáhá lékařům sledovat vývoj nemoci a účinnost léčby. [1, 3, 5]

- I. část testu (položka 1. – 4.) je zaměřena na poruchy intelektu, nálady a myšlení. Jednotlivé zaměření např. porucha myšlení je bodováno od 0 do 4, kdy 0 je normální nález a 4 maximálně vyjádřený příznak.
- II. část (položka 5. – 17.) je založena na anamnestických údajích. Zjišťujeme poruchy řeči, polykání a slinění, jak je pacient schopen zvládat běžné denní činnosti.
- III. část (položka 18. – 31.) vyšetřujeme poruchy hybnosti a účinnost léčby.
- IV. část (položka 32. – 42.) sleduje komplikace léčby např. dyskineze, vegetativní projevy.
- V. část obsahuje modifikovanou stupnici stádií Parkinsonovy nemoci dle Hoehnové a Yahra. Stupnice byla vytvořena před zavedením léčby L-DOPOU, popisuje tedy přirozený vývoj nemoci.
- VI. část slouží k zjištění funkční výkonnosti nemocného podle Schwabovy a Englandovy škály běžných činností.

## **Testy motorické výkonnosti**

Motorické testy slouží k přesnějšímu vyšetření bradykineze a pohybových schopností pacienta. Tyto testy se užívají v praxi k zjištění účinnosti léčby nebo k výzkumným studiím. Hodnotíme zde splnění daného úkolu za určitý čas, někdy je čas i předem stanovený. Vyšetřujeme pohybové zpomalení, poruchy startu, změny směru pohybu a postižení jemné motoriky. [3, 4, 6]

Jeden z testů je zkouška stoj-chůze-sed, pacient má vstát ze židle, ujít určitou vzdálenost, otočit se a vrátit se na židli. Jiný test zjišťuje pronaci a supinaci horních končetin. Zkouška obratnosti prstů se provádí tak, že nemocný ťuká palcem o všechny ostatní prsty. [3, 4, 6]

## **Reakce na dopaminergní podnět**

Zkouška reakce na dopaminergní podnět je základní vyšetření ke stanovení diagnózy Parkinsonovy nemoci. Pokud se po podání dopaminu zlepší stav hybnosti, je zachována reaktivita dopaminových receptorů ve striatu, porucha je presynaptická a jedná se tedy o PN. Jestliže se stav motorických příznaků nezlepší jedná se o Parkinsonský syndrom jiného původu. [3]

## **2.5 Zobrazovací metody**

### **Nukleární magnetická rezonance (MRI)**

U PN a Parkinsonských syndromů je na snímcích vidět zúžení pars compacta substantiae nigrae.

Protonovou magnetickorezonanční spektroskopií se prokazují specifické chemické změny substantia nigra a putamen, zatím se, ale neukázala využitelná při diagnostice PN. [3]

### **Pozitronová emisní tomografie (PET)**

Pozitronová emisní tomografie pomáhá rozlišovat PN od Parkinsonských syndromů. U PN se objevuje snížený výdej radioaktivity v putamen po podání levodopy značenou fluorem. [3]

### **Jednofotonová emisní výpočetní tomografie (SPECT)**

SPECT zobrazuje presynaptickou část dopaminergního systému. K zobrazení se používají ligandy značené radioaktivním jódem, které se vážou na presynaptické dopaminové transportéry, ukazuje tedy dopaminergní deficit ve striatu. Nelze však odlišit PN od jiných onemocnění. [3]

## **2.6 Definování chůze**

Pro pochopení chůze pacientů s Parkinsonovou chorobou je nutné znát důležitá hlediska fyziologické chůze. Fyziologická chůze slouží jako vzor při pokusných měřeních. [4]

Chůze je jeden z nejpřirozenějších a nejpoužívanějších pohybů lidského těla. Řadí se mezi lokomoci a jedná se o pohyb z místa na místo. Člověk provádí chůzi téměř nevědomě. Pro člověka je chůze jednoduchý pohyb, avšak jedná se o komplikovaný pohyb složený z mnoha částí. Každý člověk má svou typickou chůzi, která se mění po celý život. Z pohledu mechaniky je chůze řízeným pádem, při kterém tělo padá dopředu ze stabilní polohy z jedné stojné nohy na druhou stojnou nohu. [4]


Chůze je komplexní pohyb, při kterém se mohou projevit poruchy pohybového aparátu nebo nervové soustavy. Základním předpokladem pro správné vyšetření chůze je znalost krokových fází a kineziologie pohybů jednotlivých segmentů těla v každé fázi chůze. [4]

## Krokový cyklus

Krokový cyklus má dvě hlavní fáze – opornou a švihovou. Při srovnání krokových cyklů obou dolních končetin lze určit fázi dvojí opory a fázi jedné opory. Ve fázi dvojí opory jsou obě dolní končetiny zároveň ve styku s opěrnou bází. Při běhu tato fáze chybí. Základním prvkem chůze je krok, jedná se o vzdálenost mezi místy dopadu pravé a levé paty. Krokový cyklus je tvořen dvěma kroky (tzv. dvojkrokem). Dvojkrok je vzdálenost mezi místy dopadu paty jedné dolní končetiny na začátku a na konci jejího krokového cyklu. [4, 6]

Rozdělujeme krokový cyklus do těchto fází:

1. Postupné zatížení
2. Mezi stoj
3. Konečný stoj
4. Iniciální švih
5. Mezi švih
6. Koncový švih



Obr. č. 5: Popis umístění chodidel na podložce. [4]

## Parametry chůze

Pro popis chůze existují různé parametry, mezi které patří například:

- Rychlost chůze
- Délka kroku
- Délka dvojkroku
- Šířka kroku
- Kadence

Rychlost chůze je definována jako čas, který je zapotřebí k ujití určité vzdálenosti. Jednotkou rychlosti jsou metry za sekundu (m/s). Rychlost je ovlivňována vnitřními a vnějšími činiteli. Každá osoba má svou přirozenou rychlost, dle potřeby by měla být schopná ji měnit. [4, 6]

Délka kroku je definována jako vzdálenost mezi stejnými body na končetinách při jejich dopadu.

Délka dvojkroku je délka jednoho krokového cyklu, jedná se o součet délky pravého a levého kroku. [4, 6]

Šířka kroku se měří jako laterální vzdálenost mezi chodidly. Nejčastěji se měření provádí mezi středy patních kostí. Jelikož se nejedná o velkou vzdálenost, jako tomu bylo u měření délky kroku, používají se jako měřicí jednotky milimetry. Čím má člověk šířku kroku delší, tím stabilnější je jeho postoj. [4, 6]

Kadence neboli frekvence, je počet kroků za určitou časovou oblast. Jednotkou tohoto parametru je počet kroků za minutu. [4, 6]

## 2.7 Metody získání dat

### Akcelerometrie

Akcelerometrie využívá senzorů snímajících zrychlení tělesa v daném směru. Zrychlení obecně vyjadřuje míru změny rychlosti pohybujícího se segmentu. Akcelerometry mohou však také detekovat změnu náklonu měřením zemské gravitace, nebo velikost síly vznikající na základě změny rychlosti pohybu, tedy setrvačné síly. Akcelerometr se skládá ze základny, která je pevně spojená s měřeným segmentem. Dále je to pružně (známe tuhost pružiny) uloženo hmotné těleso o známé hmotnosti, jehož výchylky měříme a tlumiče. Výchylky hmotného tělesa uvnitř akcelerometru jsou například piezoelektricky převáděny a měřeny pomocí elektrického výstupního signálu. Pokud chceme měřit zrychlení ve více dimenzích, musíme použít dva nebo tři akcelerometry, jejichž osy jsou na sebe vzájemně kolmé. [4, 6]

### Dynamická plantografie

Dynamická plantografie (též nazývaná pedobarografie) je diagnostická metoda, která využívá tlakovou plošinu (obr. 103), případně pás nebo speciální vložky do bot (obr. 104) k měření rozložení tlaku pod ploškou, obvykle při chůzi či různých modifikacích stoje. S vložkami do bot se dá měřit i v terénu, tedy přirozeném prostředí pro pohyb, jehož tlakové nároky na chodidla chceme změřit. Měření probíhá v čase, přičemž dochází ke změnám hodnot sledovaných parametrů, proto mluvíme o dynamické plantografii. Měření je založeno na mechanickém stlačování senzorů rozmístěných v tlakové plošině. Senzory poskytují informace o velikosti působící síly v průběhu času, síla přepočtená na vybranou plochu senzorů je potom informací o tlaku. Můžeme tedy určit maximální tlak na jednotlivých místech nohy, průběh jeho hodnot, způsob distribuce tlaku po celém chodidle a podobně. [4, 6]

Využití dynamické plantografie nacházíme především v rámci základního výzkumu chůze či běhu, vzpřímeného stoje a jejich modifikací. Uplatňuje se v obuvnictví, v klinických aplikacích jako jsou ortopedie, neurologie, rehabilitace či protetika a ortotika, dále ve sportovní medicíně a sportovním tréninku (obr. 106). Výzkumné a diagnostické možnosti a výsledky plantografie také umožnily nedávný další rozvoj kriminalistické disciplíny zvané forenzní biomechanika. V České republice jsou v současné době využívány systémy emed, pedar, footscan nebo Baropodometer. [4, 6]

### 2.7.1 Akcelerometrie - Xsens Awinda

Xsens MVN je pohyb detekující systém s jednoduchým použitím pro měření pohybu celého těla. MVN je systém využívající miniaturní inerciální senzory s bezdrátovou komunikací spojenou se synchronizačními algoritmy, které se využívají pro znázornění biomechanického modelu postavy.



Obr. č. 6: Batoh obsahující přístroj Xsens MVN Awinda. [17]

Systém MVN Awinda obsahuje:

- 18 bezdrátových pohybových senzorů
- 1 Awinda spojovací stanice
- 2 Awinda nabíjecí stanice
- MTw velcro pásy na celé tělo, 3 trika, čelenku, 2 páry rukavic




Obr. č. 7: Pohybový senzor (MTw). [17]

Pohybový senzor (MTw) obsahuje 3D lineární akcelerometry, 3D gyroskopy, 3D magnetometry a barometr. Navíc každý jednotlivý senzor obsahuje svou vlastní baterii. Při používání 17 senzorů na těle tyto senzory měří s frekvencí 60 Hz.



Obr. č. 8: Awinda spojovací stanice. [17]

Spojovací stanice slouží ke komunikaci mezi pohybovými senzory a počítačem s programem Xsens MVN.



Obr. č. 9, 10: Rozložení pohybových senzorů MTw. [17]


## 2.7.2 Dynamická plantografie – Novel Emed-XL

Současné Emed pedografické platformy poskytují přesné, spolehlivé informace pro analýzu funkce chodidel a diagnostiku patologií. Platformy měří dynamické rozložení tlaku v průběhu fáze chůze. Pro zachycení těchto informací je velmi důležité, aby platforma mohla přesně změřit místní sílu a místní tlak. Ideální tlaková platforma bude mít prostorové rozlišení čtyř senzorů na čtvereční centimetry, ve kterých je každý senzor individuálně kalibrován. Data jsou získána velkou rychlostí měření, aby bylo možné adekvátně zachytit biomechanické složky fáze chůze. Tato měření produkují velký počet datových bodů, ve kterých je pro analýzu potřebný sofistikovaný software. Pro popis funkce nohou a kompletní analýzy chůze je zapotřebí delší platforma pro zachycení parametrů celého cyklu chůze.

Pro tuto kombinovanou aplikaci vyvinul Novel mimořádně dlouhou platformu Emed-XL. Stejně jako u stávajících Emed platforem, i Emed®-xl pracuje s kalibrovanými kapacitními senzory. Tato vlastnost platformy je základem celosvětové pověsti o přesnosti, přesnosti a reprodukovatelnosti.

Mimořádně dlouhá platforma má rozlišení senzorů 4 senzory /  $\text{cm}^2$  a obsahuje více než 25 000 senzorů. S celkovou vzorkovací frekvencí 2,5 milionu senzorů za sekundu dosahuje obnovovací frekvence 100 Hz. V délce 1,44 m může Emed®-xl zaznamenávat dva nebo tři po sobě jdoucí kroky pacienta.

Platforma Emed-XL se připojuje přímo k počítači se systémem Windows přes rozhraní USB. Synchronizační signál umožňuje synchronizaci 3D analýzy pohybu, EMG atd. Platforma také poskytuje jasnou LED diodu pro synchronizaci digitálního videa. Kromě toho je možné kombinovat dvě platformy Emed®-xl zpětně nebo vedle sebe, aby bylo možné zachytit buď dlouhé, nebo široké oblasti měření.



Obr. č. 11: Novel Emed-XL.




## 2.8 Neuronová síť

Výzkum neuronových sítí je snaha pochopit a modelovat, jakým způsobem funguje lidský mozek. Díky neurofyziologickým poznatkům byli vytvořené první zjednodušené matematické modely, které se dají využít pro neurovýpočty při řešení praktických úloh umělé inteligence. Neurofyziologie slouží jen jako inspirace a navržené modely neuronových sítí jsou již dále rozvíjeny bez ohledu na to, zda modelují lidský mozek. Stále se, ale můžeme vracet pro nové inspirace, nebo můžeme fyziologický model využít při popisu vlastností matematického modelu. [14, 15]

Nervová soustava zpracovává signály mezi vnějším prostředím a organismem. Zajišťuje tak reakci na vnější podněty a vnitřní stavy organismu. Tento proces probíhá pomocí přenosu signálů, tzv. vzruchů jednotlivých receptorů, které umožňují přijímat mechanické, tepelné, chemické a světelné podněty a dále odesílat směrem k nervovým buňkám, které tyto signály zpracovávají a přivádí k příslušným výkonným orgánům. [14, 15]

### 2.8.1 Biologický neuron

Základní stavební funkční prvek nervové soustavy je nervová buňka neboli neuron. Mozková kůra je tvořena asi 13 až 15 miliardami neuronů, z nichž každý může být spojen s přibližně 5000 jinými neurony. Vlastností neuronu je přenos, zpracování a uchování informace, která je nutná pro realizaci životní funkce organismu. [14]



Obr. č. 12: Biologický neuron. [15]


Biologické tělo neuronu se nazývá soma a obsahuje jádro, ribozomy, lysozomy a endoplazmatické retikulum. [14, 15]

Z těla neuronu vystupuje Axon. Obvykle bývá jeden na každý neuron, může dosahovat délky až 1 m. Axon přenáší signály z těla neuronu do dalších neuronů. Rychlost přenosu signálu axonem se odlišuje dle stavby axonu. Axon je obalen speciálními pochvami, některé mají tzv. Schwannovu pochvu, tvořenou Schwannovými buňkami. Jiné vlákna mají pochvu myelinovou. Čím je nervové vlákno a myelinová pochva silnější, tím rychleji vede signály. Axon vede signál zpravidla od těla neuronu a je zakončen tzv. boutony, které se připojují na dendrity, nebo tělo jiného neuronu. [14, 15]

Dendrity jsou v rozsáhlejší počtu oproti axonu a slouží jako přijímací vlákna. Jsou kratší než axon. Větévky dendritů obvykle začínají vnímavým zakončením (smyslové receptory), nebo jsou speciálně formována (hmatová tělíska). [14, 15]

## 2.8.2 Matematický model neuronu

Základem matematického modelu neuronové sítě je formální neuron. Tento formální neuron je přeformulováním zjednodušené funkce neurofyzilogického neuronu do matematického zápisu. Formální neuron má reálné vstupy simulující dendrity. Tyto vstupy jsou ohodnoceny odpovídajícími obecně reálnými synaptickými váhami, které určují jejich propustnost. [14, 15]



Obr. č. 13: Formální neuron. [15]

Tyto synaptické váhy společně se vstupními hodnotami neuronu určují vnitřní potenciál neuronu. Vnitřní potenciál indikuje samotný výstup neuronu, který modeluje elektrický impuls axonu. [14, 15]


## 2.8.3 Matematický model neuronové sítě

Model matematické neuronové sítě se skládá z formálních neuronů, které jsou vzájemně propojené tak, že výstup neuronu je vstupem obecně více neuronů podobně, jako terminály axonu biologického neuronu jsou přes synaptické vazby spojeny s dendrity jiných neuronů. Počet neuronů a jejich propojení určuje architekturu neuronové sítě. Neurony se dělí na vstupní, skryté (pracovní) a výstupní neboli vstupní odpovídají receptorům a výstupní efektorům, kdy skryté neurony vytvářejí propojení mezi nimi. [14, 15]

## 2.8.4 Klasické modely neuronových sítí

### Sít' perceptronů


Sít' perceptronů je prvním úspěšným modelem neuronové sítě. Jedná se pouze o vstupní a výstupní neurony, a tudíž nejjednodušší provedení neuronové sítě. [14]



Obr. č. 14: Architektura sítě perceptronů. [14]

## Vícevrstvá síť

Jedná se o nejznámější a nejpoužívanější model neuronové sítě. Používá se přibližně v 80 % všech aplikací neuronových sítí. Model této sítě je obecným modelem sítě perceptronů s přidáním skrytými vrstvami (tzv. vícevrstvý perceptron). Existuje mnoho modelů této sítě snažící se zlepšit vlastnosti tohoto modelu, např.: Madaline, Hopfield. [14]



Obr. č. 15: Vícevrstvá neuronová síť. [16]

Počet skrytých neuronů je volen s ohledem na složitost úlohy, standartně je tato síť učena s učitelem. Učícím algoritmem je nejčastěji back propagation error. Tyto sítě se nejčastěji používají k predikci (předpovídání), klasifikaci (třídění) a aproximaci.

### 2.8.5 Učení neuronové sítě

Cílem učení neuronové sítě je nastavit váhy modelu neuronové sítě tak, aby vytvářely správnou odezvu výstupního signálu na daný signál vstupu. Po procesu naučení neuronové sítě lze na síť pohlížet jako na black box určený k nasazení ve zvolených aplikačních rovinách neuronových sítí. [15, 16]

Používají se dvě strategie učení neuronové sítě, a to:

- Učení s učitelem,
- Učení bez učitele.

#### Učení s učitelem


Neuronová síť se snaží srovnáváním aktuálního výstupu s požadovaným výstupem (učitelem) přenastavit váhy sítě tak, aby se na daný konkrétní vstup snížil rozdíl mezi skutečným a požadovaným výstupem. [16]

#### Učení bez učitele

Váhy sítě se nastavují tak, aby výstup byl konzistentní, tedy aby síť poskytovala stejnou odezvu na budící signál při stejných, nebo podobných vektorech vstupu. [16]

### 2.8.6 Zpětnovazební síť

Zpětnovazební architektura neuronové sítě je typická tím, že určitá část neuronů v síti jsou tzv. stavové neurony, tedy neurony, které mají za úkol zachytit vnitřní stav sítě. Stav tohoto neuronu se v určitém čase považuje za výstup. Jeho hodnota je poté vedena se zpožděním zpět na vstupy dalších neuronů. [18]



Obr. č. 16: Jednoduchá zpětnovazební síť. [18]

## 2.8.7 Klasifikace

Nejdůležitější částí zpracování dat pomocí neuronových sítí je správná klasifikace výsledků výstupních neuronů. Klasifikace se provádí v závislosti na používaných modelech. Celková přesnost modelu se ovšem porovnává srovnáním výsledků sítě s požadovanými výsledky.

Často se například používá k hodnocení klasifikátorů tzv. matice záměn neboli Confusion matrix. Tato matice záměn se používá u třídění dat do tříd, nebo shluků viz. řešerše [10].

Tab. č. 4: Matice záměn

SKUTEČNÉ VÝSLEDKY	PŘEDPOVĚZENÉ VÝSLEDKY	
	POZITIVNÍ	NEGATIVNÍ
POZITIVNÍ	a	b
NEGATIVNÍ	c	d

Z této matice záměn je možné zjistit:

$$\text{Správnost} = \frac{a + b}{a + b + c + d},$$

$$\text{Precisnost} = \frac{a}{a + c},$$

$$\text{Úplnost} = \frac{a}{a + b},$$

$$\text{Specificita} = \frac{d}{c + d},$$

$$F - \text{míra} = \frac{2 * a}{(2 * a) + b + c}$$

, kde:

- správnost značí kolik dat se klasifikuje správně,
- precisnost s jakou mírou pravdy můžeme věřit výsledku správnosti,
- úplnost určuje jaký podíl skutečně pozitivních odhalíme,
- specificita určuje jaký podíl skutečně negativních odhalíme.

### 2.8.8 Mělké neuronové sítě

Mělké neuronové, jak už název napovídá jsou neuronové sítě s jednou vrstvou skrytých neuronů, oproti většího množství u hlubokých neuronových sítí. Hluboké neuronové sítě bývají zpravidla přesnější, ovšem kvůli jejich náročnosti na hardware jsou vždy systémy testovány na mělkých sítích.

Tyto neuronové sítě se nejčastěji využívají k testování různých typů neuronových sítí, protože jsou méně náročné na výpočetní jádra počítačů a také paměť. Z tohoto důvodu jsou přijatelnou možností k využití v integrovaných systémech určených na dlouhodobý sběr a vyhodnocování informací.


Mezi často používané modely mělké neuronové sítě v integrovaných systémech bývá rozpoznávání vzorů a předpovídání časových řad a modelů.

#### **Model sítě Rozpoznávání vzorů a předpovídání časových řad a modelů**

V Matlabu jsou tyto modely řešeny jako dvou vrstvé sítě, kde jedna vrstva je vrstva skrytá a druhá vrstva je vrstva výstupní. Obě tyto vrstvy obsahují určitý počet neuronů. Skrytá vrstva obsahuje nejdůležitější neurony, a to neurony skryté, viz. kapitola 2.8. Vrstvy využívají tzv. aktivační funkce, které jsou využívány k získání výstupní hodnoty. Tyto funkce jsou také známé jako tzv. převodové funkce. Aktivační funkce určují výstup neurální sítě v hodnotách od 0 do 1 nebo od -1 do 1 v závislosti na využití funkci. Aktivační funkce můžeme rozdělit na 2 typy, a to lineární a nelineární aktivační funkce.

- Lineární aktivační funkce mají lineární nárůst a jsou neukončené.
- Nelineární aktivační funkce jsou funkce nejčastěji využívané. Nelinearity pomáhá modelům adaptovat se na rozmanitá příslušná data k rozdělení na výstupní data.

Mezi nejčastěji využívanou nelineární aktivační funkcí patří funkce sigmoidní. Sigmoidní funkce nebo také nazývaná funkce logistická má tvar podobný písmenu S (Obr. č. 17). Hlavním důvodem k používání této funkce je její rozsah od 0 do 1. Z tohoto důvodu je používána pro modely kde se předpovídá pravděpodobnost, jako výstup modelu. Pravděpodobnost se může určovat jen v hodnotách od 0 do 1 a proto je v těchto modelech používanou volbou. [21]



Obr. č. 17: Křivka sigmoidní aktivační funkce. [21]

Sigmoidní funkce, také nazývaná logistická se dá matematicky vyjádřit jako: [21]

$$\Phi(z) = \frac{1}{1 + e^{-z}}$$

Kde:  $\Phi(z)$  je hodnota pravděpodobnosti

$z$  je vstupní hodnota vrstvy skrytých neuronů

Sigmoidní nebo logistická funkce může zavinit zaseknutí neuronové sítě během trénování. Z tohoto důvodu je využívána druhá aktivační funkce ve vrstvě výstupní v modelu neuronové sítě. Druhá aktivační funkce v tomto modelu je funkce softmax.

Softmax funkce je aktivační funkce která je také známá jako softargmax nebo normalizovaná exponenciální funkce. Tato funkce bere jako vstupní hodnoty vektor  $K$  reálných čísel a normalizuje je do pravděpodobnostní distribuce tvořící se z  $k$  pravděpodobností. Důvod využívání aktivační funkce softmax je její kalkulace pravděpodobnostní distribuce pro  $k$  množství vstupních hodnot, jenž odpovídají množství skrytých neuronů v neuronové síti. Hlavní výhoda této funkce je její vlastnost normalizace vstupních dat do rozsahu pravděpodobnosti od 0 do 1, kdy součet všech hodnot musí vyjít 1 (Obr. č. 18). [21, 22, 23]



Obr. č. 18: Příklad funkčnosti aktivační funkce softmax. [22]

Softmax aktivační funkce nebo normalizovaná exponenciální funkce se dá matematicky vyjádřit jako: [22, 23]

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}$$

Kde:  $\sigma(z)_j$  je normalizovaná hodnota pravděpodobnosti

$z$  je vektor vstupních hodnot na výstupní vrstvu

$K$  je index vstupních hodnot

$j$  je index výstupních hodnot od 1 do  $K$

Trénování modelů:

K trénování modelu rozpoznávání vzorů je použit algoritmus nazývaný jako Scaled conjugate gradient backpropagation, častěji odkazované jako Scaled gradient conjugate, tzv.: SGC, v překladu spojená škála gradientní zpětné propagace. Tento algoritmus je schopen trénovat jakoukoliv síť do té doby, dokud její váha, vstupní hodnoty a aktivační funkce mají derivaci. Tento algoritmus patří mezi učení s učitelem s dopředným nahráváním dat do neurální sítě. Využívá podobný koncept jako všeobecná optimalizace, ale vybírá k hledání směr a velikost kroku efektivněji tím, že používá informaci z druhé aproximace jako jsou reprezentovány v následujícím vzorci, známém také jako Taylorovo rozšíření: [24, 25]

$$E(w + y) \approx E(w) + E'(w)^T + \frac{1}{2} y^T E''(w) y$$

Kde:  $w$  je vektor váhy hodnoty ve vrstvě neuronů.

$E(w)$  je funkce globální chyby.

$w^T$  je transponovaný vektor váhy hodnoty ve vrstvě neuronů.

$E(w + y)$  je funkce chyby v jedné iteraci

Proto aby vybral algoritmus minimální globální chyby je zapotřebí, aby se našly body extrémů. Extrémy jsou výsledkem lineárního systému definovaného následujícím vztahem. [25]

$$E'(w + y) = E''(w)y + E'(w) = 0$$

Trénování modelu předpovídání časových řad a modelů se využívají 3 algoritmy, ze kterých je vybrán jeden vhodný pro implementaci podle časových a výpočetních náročností. Doporučený algoritmus pro většinu problémů je Levenberg-Marquardt. Další možností je Bayesian Regularization, který je výhodný pro malé problémy se zašuměnými daty. Trénování trvá delší dobu, ale zpravidla mívá lepší výsledek. Pro větší problémy se využívá Scaled Conjugate Gradient, jenž je popsán dříve. [26]

Levenbergův-Marquardtův algoritmus je používán k nalezení nelineárních nejmenších čtverců, jenž jsou potřebné právě k vyřešení generického přizpůsobení křivce. K přizpůsobení jakékoliv křivce je nutné najít lokální extrémy funkce. Tento algoritmus kombinuje dvě minimalizační metody, a to Gradient Descent, neboli gradient sestupu a Gauss-Newton metodu. V metodě gradientu sestupu je součet kvadratických chyb redukován aktualizací parametrů ve směru nejstrmějšího sestupu. V Gauss-



Newtonově metodě je součet kvadratických chyb snížen za předpokladu, že funkce nejmenších čtverců je lokálně kvadratická a nalezení minima je kvadratické. Levenbergova-Marquardtova metoda působí spíše jako gradient sestupu, když jsou parametry daleko od své optimální hodnoty a působí spíše jako Gaussova-Newtonova metoda, když se parametry blíží jejich optimální hodnotě. [27, 28]

$$[J^T W J + \lambda I] h_{im} = J^T W (y - \hat{y})$$

Kde:  $W$  je matice vah neuronů.

$J$  je Jacobian matice, reprezentující sensitivitu funkce.

$\lambda$  je tlumící parametr.

Ve vztahu Levenberg-Marquardt je hodnota tlumícího parametru úměrná podobnosti metody s metodami ze kterých se tato metoda odvíjí. Tlumící parametr je nastaven na vysokou hodnotu, aby první iterace trénování sítě měla malou změnu ve směru nejstrmějšího sestupu. Pokud výsledek jakékoli iterace vyjde horší aproximací, tak se poté zvýší hodnota tlumícího parametru. Jinak se tlumící parametr snižuje s každou iterací s lepší aproximací. [28]

Bayesian Regularization je algoritmus využívající matematický proces převodu nelineární regrese na dobře postavený statistický problém v podobě hřbetové regresní křivky. Výhodou tohoto algoritmu je, že model je robustní a validační proces používaný v běžných regresních metodách je nepotřebný. Je obtížné tento model přetrénovat, neboť se tento model přestane učit případě splněných kritérií. Zároveň se modely s tímto algoritmem těžko přehltní daty, protože algoritmus pracuje pouze s omezeným množstvím efektivních parametrů v síti, zatímco ostatní vypustí. [29]

Vyhodnocení účinnosti:

Účinnost neuronové sítě pro klasifikační model, který má výstupy pravděpodobnosti s hodnotami od 0 do 1, se určuje pomocí ztráty křížové entropie. Ztráta křížové entropie se zvětšuje, pokud se předpovídaná pravděpodobnost liší od skutečné hodnoty s pravděpodobností 1. Křížová entropie porovnává distribuce pravděpodobností, zadaných vstupních dat, které slouží jako „True“, skutečná distribuce a distribuce pravděpodobnosti, kterou předpověděl model klasifikační neuronové sítě. Toto porovnání distribucí určuje hodnotu ztráty, jenž značí rozdíl mezi skutečnou distribucí a předpověděnou. Hodnota ztráty určuje jak „špatná“ je předpověď distribuce od skutečné distribuce. [30, 31]

$$H(p, q) = - \sum_x p(x) * \log q(x)$$

Kde:  $p(x)$  je chtěná pravděpodobnost.

$q(x)$  je skutečná pravděpodobnost.

$H(p, q)$  je hodnota ztráty.

Další možností pro zjištění účinnosti neuronové sítě je Mean Squared Error (MSE), neboli střední kvadratická chyba. Střední kvadratická chyba je hodnota, která poskytuje informaci o dobrém přizpůsobení regresní křivky

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Kde:  $y_i$  představuje pozorované hodnoty.  
 $\hat{y}_i$  představuje předpovězené hodnoty.  
 $n$  je vektor datových bodů.

### 3. VLASTNÍ ZPRACOVÁNÍ PRÁCE

V této diplomové práci je řešena problematika detekce zamrznutí pohybu u pacientů s Parkinsonovým onemocněním. K vytvoření správné detekce byly nastudovány různé projekty a práce s detekcí pohybových artefaktů. V pracích zmíněných v rešerši [1, 2] bylo zjištěno, že je důležité správné navrhnutí experimentu vzhledem k přístrojům využitých u měření.

V kapitole 2.7 jsou zmíněny přístroje využívané v experimentu, jejich základní popis a metody detekce pohybu. S vybranými a popsányými přístroji k experimentu bylo zapotřebí vytvořit experiment ke sběru dat.

#### 3.1 Návrh řešení experimentu

K experimentu byl vybrán TUG (Timed Up and Go) testu [1]. Tento test byl vybrán z důvodu změny struktury pohybu měřené osoby, neboť v teoretické části bylo zjištěno, že pacienti s PD jsou náchylní na změny pohybu, např.: sednutí, postavení se ze židle, otočení se.

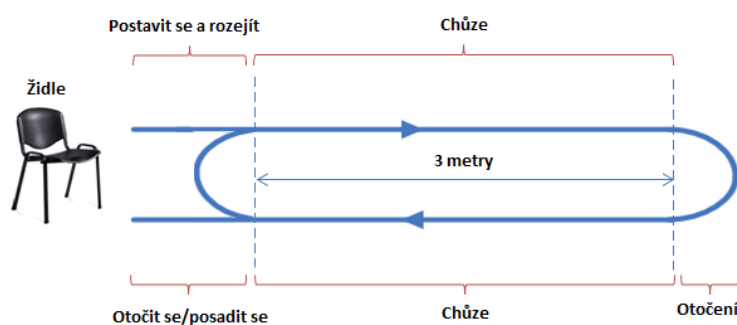
Test TUG byl upraven do 2 lehce rozdílných experimentů.

1. Měření se začátkem v sedě a celý zbytek průběhu měření ve stoje
2. Měření se začátkem v sedě a při každém návratu na původní místo si osoba opět sedla

Rozdělení tohoto experimentu na dvě různé měření sloužilo k vytvoření rozdílných datových setů, kde u druhého měření, jak je výše zmíněno, je osoba nucena sednout a tím pádem vzniká set dat s mnohem větší náchylností na zamrznutí pohybu.

Oba tyto experimenty byly doplněny lehkými matematickými úlohami v průběhu chůze po přístroji Emed-XL. Tyto otázky měli za úkol odvést pozornost měřené osoby od probíhajícího měření.

Doba přípravy experimentu byla od 15 do 30 minut, zato samotné měření trvalo od 5 do 10 minut. Nejdelší dobu v přípravě měření zabrala příprava měření přístroje Xsens Awinda.



Obr. č. 19: navrhnutý TUG test.

### 3.1.1 Průběh měření jednotlivých přístrojů

#### Xsens Awinda

Měření s přístrojem Xsens Awinda začínalo vytvořením nového měření a vytvořením profilu osoby se kterou se bude měřit. Tato osoba byla důkladně změřena dle návodu [17]. Jedná se o celotělové měření, a proto bylo potřeba změřit měřenou osobu důkladně a pečlivě, neboť na naměřených datech závisí průběh kalibrace a samotného měření.

Tab. č. 5: Měřené rozměry potřebné k vytvoření profilu v programu XSens MVN [17].

Dimenze	Popis
Výška postavy	Výška osoby od země k vrchu hlavy při vzpřímené poloze
Délka chodidla	Délka chodidla nebo délka bot (pokud má osoba boty)
Rozpětí rukou	Rozpětí paží od špičky prstů
Výška pánve	Výška pánve od země k nejvíc laterálnímu výstupku kosti pánevní
Výška kolene	Výška od země k zadní straně kolenní jamky k
Výška kotníku	Výška od země ke kosti kotníku na vnější straně nohy
Šířka pánve	Šířka pánve mezi laterálními výstupky kosti pánve
Šířka ramen	Šířka ramen mezi distálními spojeními ramen s kostmi lopatky a klíční kosti
Výška ramen	Výška od země k distálním spojeními ramen s kostmi lopatky a klíční kosti
Výška podrážky	Výška podrážky bot

Po vytvoření profilu měřené osoby se měřená osoba připraví na kalibraci, která má 2 možnosti:

1. Npose + chůze (doporučená)
2. Tpose + chůze

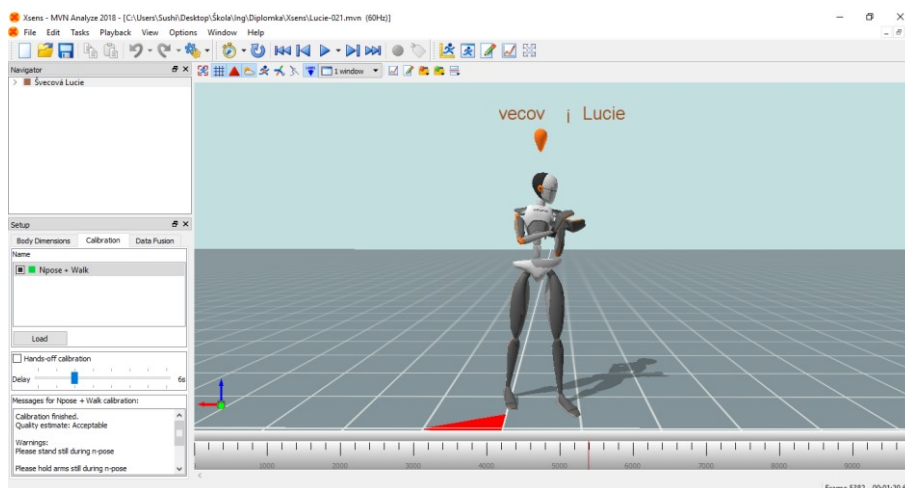
Npose je označení tzv. N pozice. Jedná se o pozici, kdy osoba je ve vzpřímeném postavení s horními končetinami podél těla a dlaněmi směrem k tělu, palce směřujíc dopředu. Dolní končetiny jsou vodorovně k sobě s chodidly směřujíc dopředu. Hlava musí směřovat dopředu a musí být zvednutá, nejlépe se dívat na protější zeď do imaginárního bodu ve výšce samotné osoby.

Tpose je označení tzv. T pozice. T pozice bývá zpravidla využívána u modelů postavy v programech. Osoba je ve vzpřímeném postavení s horními končetinami v horizontální pozici do stran od těla s dlaněmi směřujícími dolů a palci směrem dopředu. Dolní končetiny jsou vodorovně k sobě s chodidly směřujíc dopředu. Hlava musí směřovat dopředu a musí být zvednutá. Osoba tvoří tzv. písmeno T, od toho název Tpose.

Průběhy těchto kalibrací se liší pouze v pozici počáteční a konečné, kdy u pozice Npose má osoba ruce podél těla a u Tpose má ruce horizontálně a tvoří písmeno T. Při měření byl využit kalibrace Npose + chůze z důvodu jednoduššího a přesnějšího provedení. V celém průběhu kalibrace bylo

zapotřebí, aby osoba měla zvednutou hlavu a dívala se stále před sebe, následně také aby dlaně směřovali k tělu a palce dopředu. Průběhem této kalibrace osobu provázelo tzv. kalibrační video, kde bylo za úkol z počáteční pozice N se rozejít a po zhruba 3 metrech se osoba měla otočit a jít zpět na původní místo ze které kalibrace začala a tam se znovu otočit a zaujmout opět počáteční pozici N.

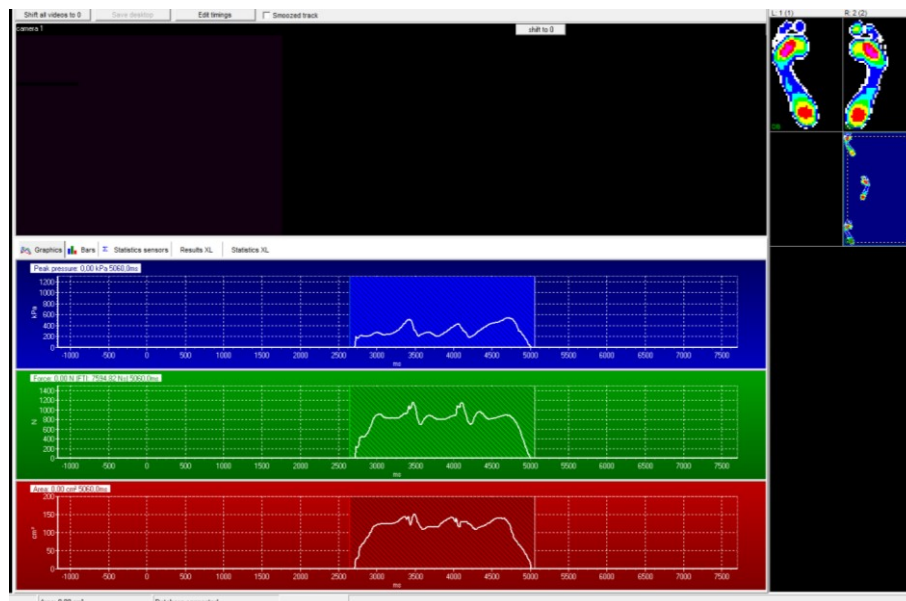
Po provedení kalibrace začalo měření, jenž probíhalo dle navrhnutého experimentu.




Obr. č. 20: Průběh měření v softwaru Xsens MVN Analyze.

## Novel Emed-XL

Měření s přístrojem Emed-XL začíná vytvořením profilu měřené osoby. V tomto profilu bylo zapotřebí zadat jméno měřené osoby, její věk, váhu a velikost chodidla. Následně se vytvořila tzv. prohlídka této osoby u lékaře. Tato prohlídka vytvořila měřicí datový set, do kterého se zapisují veškerá data získaná z měření. Poté se spustilo měření, jenž je nastaveno na měření pěti celých levých stop a pěti celých pravých stop. Kvůli komplikovanosti hardwaru přístroje je nutné, aby na měřenou plochu osoby vcházeli pouze bez obuvi a také se na měřenou plochu nesmí pokládat nebo stavět žádný další předmět. Díky tomuto omezení se židle nutná k experimentu na Obr. č. 17 postavila před měřicí plochu a osoba si sedla mimo tuto plochu bez bot. Měření je vedeno intuitivním ovládáním samotného programu, jenž dává pokyny pacientovi vždy jakmile je samotný software a hardware připraven k měření. Pokyn požívaný tímto softwarem je „Go“. Po zaznění tohoto pokynu se osoba rozešla a prošla se po měřicí ploše a na jejím konci se zastavila a otočila zpět k měřicí ploše. Software intuitivně zpracoval naměřená data a zapsal je do datového setu prohlídky dané osoby. Po zapsání a připravení se na další záznam se ozval další pokyn „Go“. Takto software pokračoval, dokud nezaznamenal 5 stop obou chodidel a poté ukončil měření. V průběhu chůze je osoba nahrávána kamerou pro vizuální porovnání a vyhodnocení chůze měřené osoby.



Obr. č. 21: Zobrazení průběhu měření s přístrojem Novel Emed-XL.



Obr. č. 22: Zobrazení průběhu měření a výstupních dat přístroje Novel Emed-XL.

### 3.1.2 Synchronizace použitého vybavení

Synchronizace je proces, jímž se více prvků v nějakém systému přivádí k organizovanému chodu nebo shodnému stavu. V tomto případě bylo nutné využít synchronizace k možnosti validace dat, kde by neorganizovaná data měření neměli žádnou váznost.


K vytvoření funkční synchronizace mezi přístroji Xsens Awinda a Novel Emed-XL, bylo nutné nastudovat manuály onou přístrojů [17, 19]. V těchto manuálech bylo zjištěno synchronizační napětí obou přístrojů a způsob synchronizace s externím vybavením.

Přístroj Xsens Awinda využívá k synchronizaci Awinda stanici. Tato stanice původně slouží jako bezdrátový „master“ k ovládání Bezdrátových senzorů. Awinda stanice byla vytvořena k ovládání, čtení záznamu a možnosti synchronizace s ostatními přístroji. Na této stanici jsou 4 BNC konektory k připojení k externím zařízením a vytvořením synchronizace. BNC konektory jsou rychle spojitelné a rozpojitelné vysokofrekvenční konektory pro koaxiální kabely. Na této stanici také najdeme napájecí konektor pro připojení do sítě a také micro USB konektor pro připojení k ovládacímu počítači.



Obr. č. 23: Připojení synchronizace k přístroji Xsens Awinda.

Přístroj Novel Emed-SL k synchronizaci používá integrované konektory v přístroji. Tyto konektory jsou ve spodní straně přístroje, ukázáno na Obr. č. 22. Mezi konektory patří USB konektor sloužící k propojení počítače a měřící plochy, přenosu dat. Další konektor je tzv. synchronizační audio konektor sloužící k synchronnímu vysílání pokynů „Go“ pomocí reproduktorů. Tento pokyn je zmíněn výše v kapitole 3.1.1. Další 2 konektory jsou konektory synchronizační vstupní a výstupní. Tyto synchronizační konektory obsahují zvláštní připojení pro 4 koaxiální kabely pro synchronizační konektor Out a 3 koaxiální kabely pro synchronizační konektor In. Tyto synchronizační kabely obsahují tyto funkční koaxiální kabely. Koaxiální kabel CLK neboli tzv. hodinový impuls slouží ke změně stavu sekvenčního digitálního elektronického obvodu, další je Active, který slouží k posílání signálu kdy je aktivní přenos a poslední je 5 V, tento kabel slouží k přenosu samotného obdélníkového signálu o amplitudě 5 V. Tyto koaxiální kabely jsou ukázány na Obr. č. 25. Poslední konektor je napájecí konektor pro napájení 16-18 V.



Obr. č. 24: Připojovací konektory přístroje Emed-XL.



Obr. č. 25: Synchronizační koaxiální kabely přístroje Novel Emed-XL.

Z manuálů k přístrojům Xsens Awinda a Novel Emed-XL [17, 19] bylo zjištěno synchronizační napětí.


Synchronizační napětí přístroje Xsens Awinda je v manuálu popsáno jako TTL pulzy. TTL je zkratka pro Tranzistor – Tranzistor Logika. TTL provádí logické tak i zesilovací funkci, kdy první tranzistor provádí logiku a druhý tranzistor provádí zesilování. TTL rozděluje vstupující signál dle




thresholdu, neboli hranice napětí na logickou nulu a logickou jedničku. Přístroj Xsens Awinda má nastavené porty na posílání a přijímání TTL pulzů 0-3.3 V.

Synchronizační napětí přístroje Novel Emed-XL je také nastaveno na TTL pulz 0-5 V.

Rozdíl v synchronizačních napětích těchto dvou přístrojů byl indikátorem k využití externího zařízení pro konvertování napětí od 5 V na 3.3 V a naopak. Manuál přístroje Xsens Awinda doporučuje v tomto případě využít SMD level translator. SMD neboli surface mounted device, přeloženo jako zařízení namontované na povrchu, jsou malé součástky s nejčastěji jednou funkcí namontované na desky plošných spojů. Level translator slouží ke změně úrovně napětí mezi vstupním bodem a bodem výstupním. Nakonec byl vybrán SMD Logic Level Converter neboli bi-directional Level Shifter, Obr. č. 26.



Obr. č. 26: Sparkfun logic level convertor.




Obr. č. 27: Schéma jednoho kanálu Logic Level Converteru [20].

Z dokumentace Logic Level Converteru [20] bylo zjištěno, že tento Converter obsahuje 4 totožné kanály obsahující jeden N-kanál MOSFET a 2 rezistory k vytvoření obou směrné změny napětí. MOSFET je zkratka pro Metal Oxide Semiconductor Field Effect Transistor. Jedná se o tranzistor řízený elektrickým polem, u kterého je vodivost kanálu mezi elektrodami zdroje a odtoku ovládána elektrickým polem vytvářeným ve struktuře kov-oxid-polovodič napětím přiloženým mezi zdrojem a hradlem, tzv. Gate. Hradlo je od polovodiče odděleno vrstvou oxidu křemíku.

K synchronizaci externích přístrojů je nutné vytvořit propojení mezi těmito přístroji, jak je zmíněno výše. Propojení tedy nastává pomocí koaxiálních kabelů a nutného level converteru. Synchronizace je proces, kdy jsou přístroje rozděleny do patentních stavů, kdy je jeden přístroj, nejčastěji ten důležitější nastaven jako Master, což znamená, že tento přístroj bude vysílat synchronizační impuls všem ostatním přístrojům s ním propojeným. V našem případě byl vybrán přístroj Novel Emed-XL jako Master v synchronizaci. Přístroj Xsens Awinda byl tedy v našem případě Slave, což je označení pro systém čekající na synchronizační impuls od Master přístroje v našem případě Novel Emed-XL.

Synchronizace měření využitých přístrojů posloužila k možnosti přesného sjednocení měřených dat k jejich následnému uložení do vytvořené databáze viz. kapitola 3.2. K sjednocení těchto dvou získaných datových souborů, bylo zapotřebí oba soubory převést na jeden společný formát vhodný ke zpracování. V této části byl zvolen formát .csv a následně byly sjednoceny tyto datové soubory do jednoho dle datového typu Time Stamp, což znamená časová stopa. Toto sjednocení pomocí datové stopy sloužilo jako další způsob synchronizace dat, ovšem synchronizace řešená dříve v této kapitole šetřila zatížení paměti, neboť spouštěla měření pro oba přístroje v jednu chvíli, a to posloužilo k menší náročnosti pro paměť i pro načtení dat ve vytvořeném algoritmu.

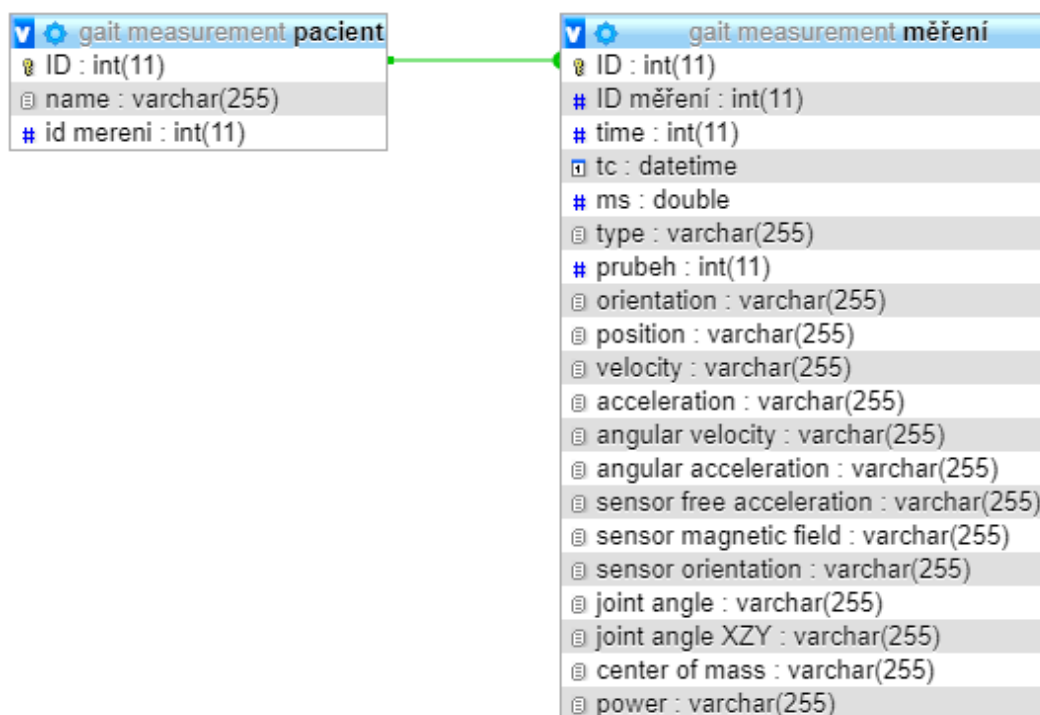


Obr. č. 28: Synchronizovaná data z měření na přístrojích

## 3.2 Návrh databáze pro uložení naměřených dat

Byla navržena databáze pro online uložení dat. Tato databáze byla vytvořena pomocí jazyka MySQL. Vytvořená databáze byla nahrána na server Google cloud SQL. Data se pro uložení do databáze upravily do formátů .csv, jenž patří mezi textový formát s oddělenými informacemi čárkou.

Do databáze byly nahrány veškerá data z provedeného experimentu, který byl proveden na 19 osobách v kontrolní skupině. Měření experimentu se neprovedlo na pacientech s Parkinsonovým onemocněním z důvodu nepovolené klinické studie s pacienty PD. Pro zpracovávání dat je využívána pouze druhá tabulka měření. K tabulce pacient není udělen přístup z důvodu obecného nařízení o ochraně osobních údajů neboli GDPR.



Obr. č. 29: Relace databáze

Na obrázku č. 33:

- ID měření je číselné označení typu experimentu,
- type je označení, zda probíhá měření, nebo pouze kalibrace senzorů přístroje Xsens Awinda,
- průběh je auto inkrementální číselný průběh měření,
- power jsou data měřená přístrojem Emed-XL,
- orientation až center of mass jsou data měřená přístrojem Xsens Awinda.

### 3.3 Návrh algoritmu

Rešeršní část byla zaměřena na předchozí práce a projekty zabývající se detekcí anomálií v průběhu chůze. Ze zjištěných informací byl vybrán experiment pravidelně využíván právě k tomuto účelu. Tento experiment zajistil možnost využít již dříve naměřené datové sety, a to již datové sety s pacienty s Parkinsonovým onemocněním a také kontrolní pacienty. Na těchto datových setech se navrhovaný algoritmus navrhnul a zároveň se na těchto datových setech tento algoritmus testuje.

Pro nalezení datových setů se z analyzovaly vybrané přístroje a jejich výstupní informace, tj. přístroj společnosti XSens měří pomocí inerciálních senzorů zrychlení v 6G. Přístroj společnosti Emed měří pomocí matice tlakových senzorů, které zjišťují sílu působící na měřící plochu.


Ze zjištěných výstupních údajů přístrojů se vybrali datové sety obsahující data naměřených pacientů a kontrolních osob, dle podobnosti prováděného měření k vytvořenému experimentu.

Nakonec byly vybrány 3 datové sety:

- První datový set nese jméno Gait in Parkinson's Disease [datový set 1]
  - V tomto datovém setu použili celkově 16 senzorů kde tyto senzory vložili do podložky nohy, 8 pro každé chodidlo.
  - Senzory měří sílu (v Newtonech jako funkci času) došlapujícího chodidla na podložku (v tomto případě zem).
- Druhý datový set nese jméno Daphnet Freezing of Gait Data Set [datový set 2]
  - V tomto datovém setu použili pouze 3 senzory tzv. akcelerometry.
  - Tyto akcelerometry jsou rozmístěny na křížové kosti a poté 2 na jedné noze, konkrétně levé, a to jeden na kolenu a poslední nad kotníkem.
  - Senzory měří zrychlení vůči zemi, a to ve třech osách.
- Třetí datový set nese jméno Human Gait Database for Activity Recognition from Wearable Inertial Sensor Networks [datový set 3]
  - V tomto datovém setu použili 6 senzorů tzv. akcelerometry/gyroskopy.
  - Tyto akcelerometry jsou rozmístěny na chodidle, holení kosti a stehnu. Stejně na obou nohách.
  - Senzory měří zrychlení vůči zemi, a to ve třech osách.


První část porovnání mezi navrhnutým experimentem s přístroji: (Xsens Awinda a Novel Emed-XL) a vybranými datovými sety výše zmíněnými v kapitole bylo rozložení senzorů. Tato informace je velice důležitá k možnosti porovnávání výsledků a také validaci správných výsledků z měřených dat experimentu.

V prvním datovém setu [datový set 1] je rozložení senzorů ve vložkách bot ukázané na Obr. č. 29, kdy je 8 tlakových senzorů v levé vložce a 8 tlakových senzorů v pravé vložce. Rozdíl mezi tímto datovým setem a přístrojem Novel Emed-XL ve sběru dat je zanedbatelný, neboť přístroj Novel Emed-XL měří ve velké ploše a je schopen zaznamenat celou stopu taktěž jako senzory v prvním datovém setu. Datový set taktěž využívá celkovou sílu působící na všechny senzory v dané vložce stejnou funkci má také přístroj Novel Emed-XL při zobrazení jednotlivých stop, dle Obr. č. 19.



Obr. č. 30: Rozložení senzorů v datovém setu Gait in Parkinson disease.

V druhém a třetím datovém setu jsou využity inerciální senzory [datový set 2, datový set 3], kdy u datového setu 2 jsou využity 3 inerciální senzory s rozložením ukázaným na Obr. č. 31 a v datovém setu 3 je využito 6 senzorů kdy jsou rozloženy senzory na kotnících, kolenech a vnějších stranách steh. Tyto rozložení senzorů je stejné jako rozložení senzorů u přístroje Xsens Awinda na Obr. č. 9 a 10. Jediný rozdíl je menší počet senzorů, ale rozložení senzorů odpovídá některým používaným senzorům v experimentu.



Obr. č. 31: Umístění senzorů v datovém setu Daphnet Freezing of Gait Data Set. [datový set 2]

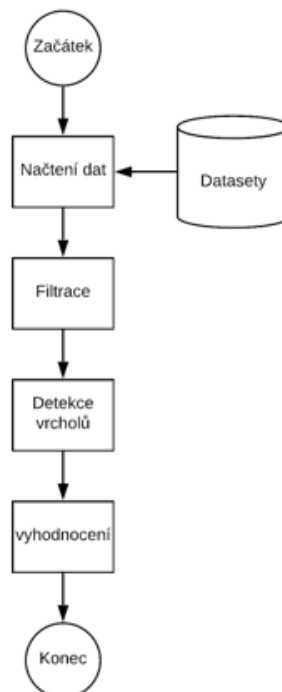
Další částí bylo navrhnutí algoritmu, jenž byl vytvořen v programu Matlab. Načítání samotných datových setů probíhá přes jednoduchý cyklus za využití několika funkcí. Složitější část nastává v rozdělení dat podle datového setů, neboť první datový set se liší výstupními daty od zbylých dvou datových setů.

Data měřená tlakovými senzory pro přístroj Novel Emed-XL již byli nahrazeny předchozím datovým setem [datový set 1]. Následným krokem bylo nalezení a načtení datového setu pro data z pohybových senzorů na těle pacienta jako u přístroje Xsens Awinda. Z tohoto důvodu byli vybrány datové sety 2 a 3, kde datový set 2 [datový set 2] obsahuje data naměřených pacientů s Parkinsonovým onemocněním. Bohužel datový set 2 obsahoval pouze měření pro pacienty s Parkinsonovým onemocněním. Taktéž se v tomto datové setu měřilo pouze se 3 inerciálními senzory. Inerciální senzory měřily pro pohyb ve třech základních osách. Osa horizontální dopředu, osa vertikální a osa horizontální laterální. Poslední je anotovaná kontrola dat pro průběh měření v čase kdy hodnota 0 znamená měřená data mimo vybraný experiment, hodnota 1 data měřená v experimentu a hodnota 2 znamená zamrznutí pohybu v průběhu měření experimentu.

Datový set 3 [datový set 3] obsahuje druhou skupinu dat pro prováděné měření s akcelerometry na kontrolní skupině. V tomto datovém setu je výhoda více inerciálních senzorů používaných v měření. Používaly se zde inerciální senzory na obou dolních končetinách, a to zaručilo přesné stanovení došlápnutí jednotlivých chodidel k základnímu vyhodnocení.


### 3.3.1 Zpracování datových setů

Průběh zpracování datových setů je popsán ve vývojovém diagramu usnadňujícím logiku zpracování jednotlivých datových setů.




Obr. č. 32: Vývojový diagram zpracování datových setů.

Načtená data z datových setů jsou díky citlivosti inerciálních a tlakových senzorů velice kóstrbatá. Z tohoto důvodu bylo zapotřebí vyhladit tyto data pomocí filtru. Byl navrhnut filtr, jenž by daný signál vyhladil, a zároveň nepotlačil důležité části signálu. Dolnoproustný filtr typu FIR, který slouží k odstranění šumu signálu a přesnější detekci vrcholů pro vyhodnocení parametrů chůze. Byl aplikován funkcí Matlabu `fir1`, jenž je FIR filtr na bázi okenní funkce. Použitý filtr byl nastaven se vzorkovací frekvencí 100 kHz, Cutoff frekvencí 150 Hz. CutOff frekvence je hranice ve frekvenční odezvě systému, při které se energie, která protéká systémem, začíná snižovat, spíše než procházet. Pořadí filtru neboli order filter byl nastaven na 20 a určuje množství dalšího útlumu pro frekvence vyšší než mezní frekvence. Jako okenní funkce bylo nastaveno Kaiser okno, které se používá k filtrování konečných impulsu a spektrální analýzy.



Obr. č. 33: Frekvenční charakteristika low pass FIR filtru použitého k odfiltrování šumu.

Po vytvoření FIR filtru byl tento filtr použit na všechny datové sety k vyhlazení signálu pro detekci parametrů.



Obr. č. 34: Ukázka vlivu aplikovaného dolnoproustného filtru na data z tlakového senzoru [datový set 1].

Následně bylo zapotřebí detekovat vrcholy signálu k možnosti vyhodnocení parametrů chůze. K detekování vrcholů byla využita funkce `findpeaks`. Tato funkce byla využita pro všechny datové sety. `Findpeaks` využívá dvou kritérií pro vyhledávání vrcholů, a to `MinPeakHeight` a `MinPeakDistance`. Funkce byla nastavena s parametry hledání minimální velikosti vrcholu signálu, tzv. `MinPeakHeight`. Hodnota minimální velikosti vrcholu byla vypočtena pro každý signál v datovém setu zvlášť a to jako:

$$\text{MinPeakHeight} = \max(y) - \text{quantile}(y, x)$$


Kde:  $y$  je signál jednoho měření.

$x$  je hodnota nastaveného quantilu



Hodnota MinPeakDistance byla nastavena pro jednotlivé datové sady zvlášť podle vlastností měření jednotlivých přístrojů, např. datový set 1 zaznamenával data s frekvencí 100 Hz, a proto byl nastaven MinPeakDistance na hodnotu 100. Zatímco pro datový set 2 byla nastavena hodnota 1.

Přesnost nalezení vrcholů byla provedena vizuálně.



Obr. č. 35: Ukázka detekování vrcholů v signálu z obrázku č 35.

K vyhodnocení byl vybrán detekovaný parametr doby došlápnutí chodidla. V tomto případě vrcholy značí došlápnutí chodidla na zem. K výpočtu byly využity jednoduché cyklické funkce, které byly spojeny spolu s výpočty daných hodnot v Matlabu: mean a var.

```
% výpočet doby dvojkroku pravé nohy CO
l=length(tizo_rpeakCo(i).value);
x_rCo(i).value=zeros(1,l);
for q=1:l-1
    if tizo_rpeakCo(i).value(q+1)==0
        break;
    else
        x_rCo(i).value(q)=tizo_rpeakCo(i).value(q+1)-tizo_rpeakCo(i).value(q);
        x_rCo;
        var_rCo(i).value(q)=var(x_rCo(i).value);
        var_rCo;
    end
end
avg_rCo(i).value=mean(x_rCo(i).value);
avg_rCo;
```

V tomto případě se jedná o funkční cyklus v Matlabu, jenž zjišťuje průměrnou dobu pro dokončení dvojkroku a také variabilitu doby dvojkroku pravé nohy u kontrolní skupiny. Podmínka if zde slouží jako kontrola pro případ, kdyby již další hodnota na časové ose neexistovala, aby nedošlo ke zkreslení výsledků.

Hodnota: tizo\_rpeakCo označuje hodnotu na časové ose kdy došlo k došlápnutí chodidla pravé nohy na zem.

x\_rCo označuje hodnotu doby potřebné k dokončení jednoho dvojkroku pravé nohy.

var\_rCo označuje hodnotu variability doby jednoho dvojkroku pravé nohy.

avg\_rCo označuje průměrnou dobu k dokončení jednoho dvojkroku pravé nohy.

Výpočet průměrné doby došlápnutí (mean):

Kde pro náhodný vektor A tvořen N skalárními počty měření je průměr definován jako

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i$$

Výpočet variability doby došlápnutí (var):

Kde pro náhodný vektor A tvořen N skalárními počty měření a průměrnou délkou kroku  $\mu$  je variance definovaná jako

$$V = \frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2$$

Detekované doby došlápnutí chodidla na zem byly uloženy a zpracovány do tabulky, kde byly vyhodnoceny rozdíly mezi kontrolní skupinou a skupinou s Parkinsonovým onemocněním. Mezi porovnávané parametry byly vybrány délka trvání kroku, délka trvání dvojkroku.

Tab. č. 6: Porovnání rozdílů v parametrech chůze kontrolní skupiny se skupinou pacientů s Parkinsonovým onemocněním.

		Datový set 1	Datový set 2	Datový set 3	Průměr
<b>Kontrolní skupina</b>	Průměrná Doba jednoho Kroku, levá-pravá [s]	0.584	/	0.576	0.58
	Průměrná variabilita v době jednoho kroku [s]	0.059	/	0.068	0.0635
	Průměrná Doba dvojkroku, levá-levá [s]	1.187	/	1.170	1.1785
	Průměrná variabilita doby dvojkroku, levá-levá [s]	0.123	/	0.130	0.1265
	Průměrná Doba dvojkroku, pravá-pravá [s]	1.193	/	1.186	1.1895
	Průměrná variabilita doby dvojkroku, pravá-pravá [s]	0.118	/	0.124	0.121
<b>PD</b>	Průměrná Doba jednoho Kroku, levá-pravá [s]	0.523	0.507	/	0.515
	Průměrná variabilita v době jednoho kroku [s]	0.137	0.156	/	0.1465
	Průměrná Doba dvojkroku, levá-levá [s]	1.099	1.146	/	1.1225
	Průměrná variabilita doby dvojkroku, levá-levá [s]	0.267	0.294	/	0.2805
	Průměrná Doba dvojkroku, pravá-pravá [s]	1.125	1.134	/	1.1295
	Průměrná variabilita doby dvojkroku, pravá-pravá [s]	0.234	0.221	/	0.2275

Porovnání rozdílů v parametrech chůze ukázalo, že pacienti s Parkinsonovým onemocněním mají 2.3x větší variabilitu doby jednoho kroku, než osoby v kontrolní skupině což potvrzuje závěry článků uvedených v rešerši []

### 3.4 Výstup měření experimentu

Dle dříve definovaného experimentu bylo provedeno měření s přístroji Xsens Awinda a Novel Emed-XL. První částí bylo vyexportování naměřených dat do programu Matlab ke zpracování rozdílu parametrů u kontrolní skupiny v datových setech a měřené skupiny v experimentu.

Měřicí přístroj Xsens Awinda obsahuje velké množství inerciálních senzorů dle kapitoly 2.7.1. Z tohoto důvodu bylo zapotřebí vybrat pouze některé inerciální senzory k porovnání vypočtených parametrů z datových setů a měření. Datové sety 2 a 3 používají inerciální senzory pouze na dolních končetinách, a proto byly k porovnání vypočtených dat zvoleny právě tyto senzory.

Umístění většiny inerciálních senzorů je velice důležité. Hlavně kvůli typu problematiky experimentu, který se provádí na měření. V případě této práce se dá vyhodnotit tato problematika detekce zamrznutí pohybu pouze s jedním inerciálním senzorem, a to na pánvi. Ovšem mezi nejčastěji používané senzory pro detekování anomálií pohybu je inerciální senzor umístěný na holení kosti. [32]

Funkčnosti senzorů pro detekci parametrů řešených v kapitole 3.3 se liší v závislosti na umístění senzoru. Například inerciální senzor na dlani horní končetiny nemá téměř žádné relevantní naměřená data k detekci kroků. Z tohoto důvodu se dají tyto inerciální senzory rozdělit dle relevantnosti naměřených dat pro detekci pohybu a zároveň detekci zamrznutí pohybu. Typicky se jedná o pohyb a omezení pohybu hlavně dolních končetin, proto se zpravidla využívají k detekcím těchto parametrů právě inerciální senzory dolních končetin, neboť ve své vertikální ose mají největší rozpětí naměřených dat a zbylé dvě osy neprojevují větší rozdíl.

K výpočtu a porovnání parametrů byl vybrán první segment. První segment je pánev, dle manuálu [17]. bylo zapotřebí vyhladit signál s naměřenými daty, zde se znova využilo low pass FIR filtru vytvořeného v kapitole 3.3. Následně bylo využito funkce findpeaks k nalezení vrcholů. Tyto vrcholy byly následně použity k výpočtu parametrů k porovnání s parametry datových setů. Ukázka detekce vrcholů u naměřených dat v experimentu Obr. č. 28. Obr. č. 28 ukazuje synchronizovaná data měření experimentu.

```
% výpočet doby jednoho kroku
l=length(tp);
x_lPt(j).value=zeros(1,l);
for q=1:l-1
    if tp(q+1)-tp(q)>200
        break;
    else
        x_lPt(j).value(q)=tp(q+1)-tp(q);
        x_lPt;
        var_lPt(j).value(q)=var(x_lPt(j).value);
        var_lPt;
    end
end

avg_lPt(j).value=mean(x_lPt(j).value);
avg_lPt;
```

Uvedená část kódu je částí algoritmu pro výpočet doby jednoho kroku pro datové sety s inerciálními senzory. Hlavním rozdílem je změna podmínky if, pokud rozdíl mezi dvěma následujícími hodnotami přesáhne zadaný treshhold, pak se ukončí tato iterace cyklu a přejde se na další kde již bude zase v pořádku detekovat doby došlápnutí kroků.

Tab. č. 7: Vypočítané hodnoty parametrů chůze v experimentu.

Měřené osoby	Kontrolní skupina					
	Průměrná doba jednoho kroku, levá-pravá [s]	Průměrná variabilita doby jednoho kroku, levá-pravá [s]	Průměrná Doba dvojkroku, levá-levá [s]	Průměrná variabilita doby dvojkroku, levá-levá [s]	Průměrná Doba dvojkroku, pravá-pravá [s]	Průměrná variabilita doby dvojkroku, pravá-pravá [s]
Osoba 1	0.564	0.0647	1.114	0.1246	1.1817	0.112
Osoba 2	0.531	0.0794	1.123	0.1321	1.1453	0.1267
Osoba 3	0.61	0.0741	1.213	0.1437	1.226	0.1468
Osoba 4	0.573	0.0697	1.134	0.1348	1.128	0.1348
Osoba 5	0.54	0.0657	1.104	0.1398	1.117	0.1347
Osoba 6	0.602	0.0713	1.234	0.1452	1.218	0.1499
Osoba 7	0.597	0.0797	1.176	0.1567	1.181	0.1541
Osoba 8	0.549	0.0624	1.085	0.1248	1.067	0.1237
Osoba 9	0.522	0.0648	1.034	0.1387	1.098	0.1348
Osoba 10	0.578	0.0754	1.167	0.1534	1.197	0.1538
Osoba 11	0.615	0.0688	1.246	0.1389	1.184	0.1401
Osoba 12	0.551	0.0598	1.127	0.1164	1.134	0.1134
Osoba 13	0.498	0.0684	1.004	0.1367	1.012	0.1397
Osoba 14	0.57	0.0719	1.167	0.1438	1.161	0.1458
Osoba 15	0.572	0.0694	1.138	0.1401	1.159	0.1399
Osoba 16	0.597	0.0612	1.184	0.1231	1.187	0.1249
Osoba 17	0.593	0.0685	1.138	0.1344	1.134	0.1158
Osoba 18	0.538	0.0634	1.038	0.1216	1.068	0.1237
Osoba 19	0.514	0.0649	1.098	0.1278	1.034	0.1309
Průměr	0.5639	0.0686	1.1328	0.1356	1.1385	0.1340

Tab. č. 8: Porovnání parametrů chůze mezi kontrolními skupinami v datových sítích a měřené skupině v experimentu.

	Kontrolní skupina					
	Průměrná doba jednoho kroku, levá-pravá [s]	Průměrná variabilita doby jednoho kroku, levá-pravá [s]	Průměrná Doba dvojkroku, levá-levá [s]	Průměrná variabilita doby dvojkroku, levá-levá [s]	Průměrná Doba dvojkroku, pravá-pravá [s]	Průměrná variabilita doby dvojkroku, pravá-pravá [s]
Průměr datových sítí	0.58	0.0635	1.1785	0.1265	1.1895	0.121
Průměr měření	0.5639	0.0686	1.1328	0.1356	1.1385	0.1340


Ze zjištěných dat v tab. č. 13 je patrné, že rozdíly mezi kontrolními skupinami pro datové sety a vlastní měření je minimální. Statisticky nevýznamný rozdíl v těchto datech potvrzuje správnost měření a zpracování dat.

Algoritmus pro hledání určených parametrů v předem připravených datových setech byl zároveň otestován na naměřených datech experimentu. Následně byl vyhodnocen a porovnán s již získanými daty z datových setů.

### 3.5 Navrhnutí algoritmu detekce zamrznutí pohybu

Návrh algoritmu k detekci zamrznutí pohybu byl vytvořen vzhledem k již prováděným projektům s úkolem detekovat anomálie v datech. Bylo vybráno řešení pomocí neuronových sítí dle vypracovaných rešerší a teoretického rozboru. Konkrétně byly vybrány metody Neural Net Time Series (NNTS), neboli předpovídání časových řad a modelů a Neural Net Pattern Recognition (NNPR), neboli předpovídání vzorů. Pro oba modely se předpokládalo s již naměřenými daty a pozdějším vyhodnocování dat. Tento typ učení je známý jako učení s učitelem.

K natrénování neuronových sítí byl vybrán Daphnet Freezing of Gait Data Set [datový set 2], neboť obsahuje data měření osob s PD a výslednými indikátory zamrznutí pohybu, viz. kapitola 3.3 Obr. č. 32. Data výsledných indikátorů byla upravena dle anotace samotného datového setu pro správnost fungování navrhovaného algoritmu, a to tak, že veškerá data anotace museli být upraveny na pouze 2 výstupní hodnoty. Výstupní data byla nastavena na 2 výstupní kritéria, kdy splňovali data podmínku anomálie (zamrznutí pohybu) a kdy nesplňovali podmínku. Data jednoho měření byla vybrána k natrénování sítí a poté se neuronová síť testovala na zbytku dat z datového setu. Neuronové sítě byly trénovány na datech, které nebyli předzpracovány, tzn. nebyli zkráceny na poměr 1:1 pro výstupní a vstupní data a nebyli filtrováni z důvodu zachování původních dat měření a nevytváření zkreslení. Data nebyla předzpracována z důvodu vytvoření neuronové sítě schopné zpracovávat tzv. „hrubé“ data z měření.



Obr. č. 36 Základní model neuronové sítě.

Jako vstupní data byly nahrány všechny data kromě výsledných dat. Výsledná data byla nahrána jako data anotace. Pro oba typy neuronových sítí bylo nastaveno 50% vstupních dat na trénování, 25% dat na validaci a 25% dat na testování.

### 3.5.1 Neural Net Pattern Recognition

Jedná se o model neuronové sítě fungující způsobem třídění vstupních dat do objektů nebo tříd v závislosti na požadovaných vlastnostech výstupních dat. Byl navržen dvouvrstvý dopředu doplněný model se sigmoidní aktivační funkcí a 10 skrytými neurony a 2 neurony ve výstupní vrstvě s aktivační funkcí softmax. Síť byla trénována odstupňovanými zpětnými propagacemi konjugovaného gradientu. Správnost modelu je evaluována pomocí křížové entropie a matice záměn.

Tab. č. 9: Výsledky trénování NNPR

	<b>POČET VZORKŮ</b>	<b>KŘÍŽOVÁ- ENTROPIE</b>	<b>CHYBA [%]</b>
Trénování	75993	2.36183	3.34
Validace	37997	3.48034	3.55
Testování	37997	3.48586	3.37

Výpočet účinnosti trénování neuronové sítě pomocí křížové-entropie je popsán v kapitole 2.8.8.

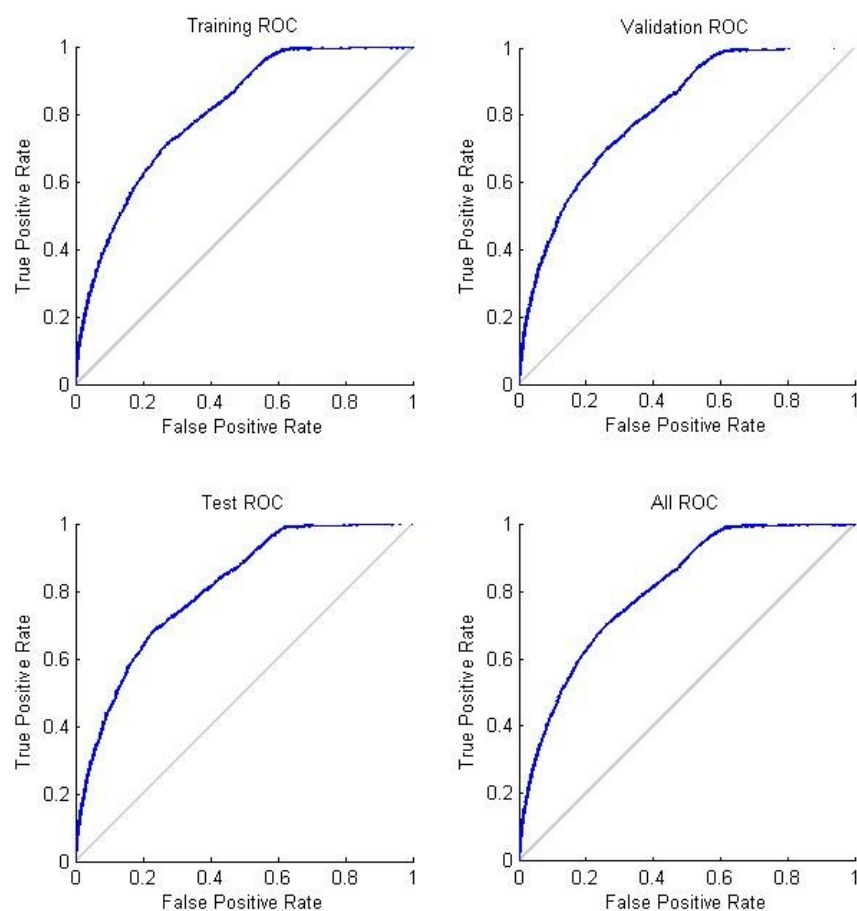
Hodnota chyby je popsána v matici záměn jako správnost, která byla popsána v kapitole 2.8.7. Chyba indikuje množství špatně klasifikovaných dat.






Obr. č. 37: Matice záměn trénování modelu NNPR.

Výsledek trénování modelu neuronové sítě rozeznání vzorů z obrázku č. 37 ukazuje, že se v tomto modelu potýkáme s velkou nepřesností detekování výsledných hodnot (target). Z výsledku celkové míry přesnosti a F-míry v pravém dolním rohu je vidět velká přesnost naučení modelu, v tomto případě to má ovšem za následek nepřesné definování dat, které ještě model neviděl viz. Obrázek č. 41, 42.




Obr. č. 38: Graf ROC.

Graf ROC neboli Křivka zpětné operační charakteristiky, udává opravdové pozitivní hodnoty (senzitivitu) oproti falešné pozitivní hodnotě (specifické). V perfektním případě by tento graf měl procházet levým horním rohem, naznačujíc 100% senzitivitu a 100% specifitu.



Obr. č. 39: Matice záměn NNPR na prvních testovacích datech.



Obr. č. 40: Graf ROC testovacích dat pro první testovací data

Zbylé testovací data vycházely s minimálními rozdíly, a tudíž nejsou uvedeny graficky, ale pouze v tabulce č. 7. Z předchozích poznatků se potvrdila malá přesnost modelu NNPR.

Tab. č. 10: Výsledky testování NNPR.

	<b>KŘÍŽOVÁ-ENTROPIE</b>	<b>CHYBA [%]</b>
Testování 1	0.152042	3.24407
Testování 2	0.181234	5.01646
Testování 3	0.280832	9.15276
Testování 4	0.357477	11.25043
Testování 5	0.247510	6.25677
Testování 6	0.118369	7.54244
Průměr	0.222910	7.07715


Z dosažených výsledků je patrné, že k tomuto typu algoritmizace neuronové sítě se tento model statisticky nehodí z důvodu nepřesnosti detekování výsledných hodnot na obrázku č. 38.

Metoda NNPR fungující způsobem třídění dat do objektů nebo tříd v závislosti na naučených skrytých neuronech a jejich nastavených parametrech dle požadovaných výsledků. Přesnost trénování sítě byla stanovena pomocí F-míry, která byla vypočítána z matice záměn. Hodnota F-míry je znázorněna v modrém čtverci pravého spodního rohu. Při trénování sítě NNPR výsledná data vykazovala velkou přesnost s F-mírou 96,7 % ovšem pro zkontrolování přesnosti detekování hledaných výsledků stačí sečíst správnosti, přesnosti, úplnosti a specifcity a vydělit je součtem jejich maximální přesnosti. Výsledná přesnost detekce hledaných výsledných hodnot při trénování vychází pouhých 58,6 %. Následně při testování je celková přesnost detekce výsledných hodnot pouhých 49,5 %. Velký rozdíl mezi celkovou přesností detekce sítě a její F-mírou naznačuje špatné natrénování sítě. Ke správnému natrénování by musely být data předzpracovány dle řešeršní části [10] do poměru 2:1, kde na každý chtěný výsledný index, byly k dispozici 2 hodnoty k natrénování.

### 3.5.2 Neural Net Time Series

Tento model funguje na principu dynamického filtrování, ve kterém se hodnoty starého, v tomto případě trénovacího setu budou používat pro předpovězení budoucích hodnot.

K vytvoření byl použit nelineární autoregresní model s externím vstupem dat, který se používá v případě předpovídání dat s neustále novými vstupními daty. Pro trénování byl zvolen Levenbergův-Marquardtův zpětně propagační algoritmus. Tento algoritmus slouží k rychlejšímu trénování pomocí aproximace matic potřebných k trénování neuronových sítí.



Obr. č. 41: Obecné schéma nelineárního NNTS modelu.

Schéma udává nastavení sítě s hodnotami 10 skrytých neuronů a 2 odložení neboli „delay“, jenž byli využity v tomto modelu.

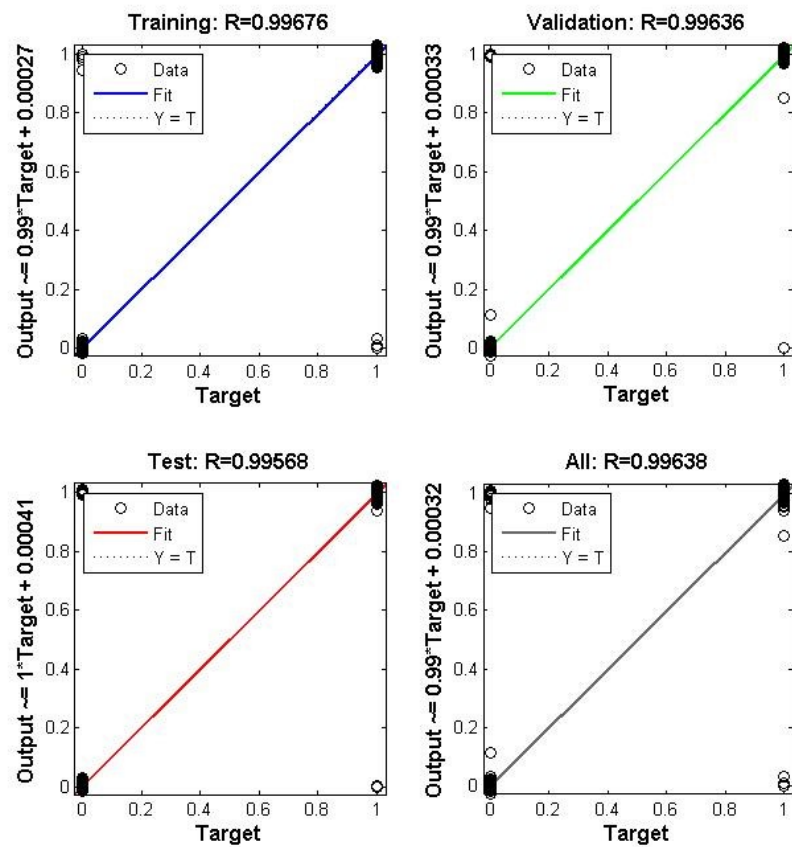
Tab. č. 11: Výsledky trénování NNTS.

	POČET VZORKŮ	MSE	REGRESE R
Trénování	75993	2.08680e-4	0.996760
Validace	37997	2.38251e-4	0.996357
Testování	37997	2.90491e-4	0.995677


Hodnota MSE udává střední kvadratickou chybu mezi výstupem a nahanou výslednou hodnotou. Hodnota MSE je popsána v kapitole 2.8.8.

Hodnota Regrese R udává vztah mezi hodnotou výstupu a chtěnými výsledky. Z této hodnoty vyplývá graf Regrese ukazující korelaci mezi těmito hodnotami. Přesnost trénování sítě zde byla stanovena právě pomocí hodnoty regrese. Hodnota regrese se počítá jako:

$$\text{regrese} = (\text{průměrná hodnota dat s validací 1}) * \text{výsledná hodnota} + (\text{průměrná hodnota s validací dat 0})$$



Obr. č. 42: Graf regrese trénování NNTS.




Obr. č. 43: Výstup trénování se znázorněnými chybami.

Tab. č. 12: Výsledky testování NNTS.


	POČET DAT	REGRESE R
Testování 1	52095	0.995464
Testování 2	72561	0.991348
Testování 3	89645	0.995907
Testování 4	144190	0.993597
Testování 5	38774	0.994661
Testování 6	70269	0.995379
Průměr	69239.83	0.994393

Testování modelu NNTS ukázalo výbornou korelaci mezi výstupními hodnotami a výslednými hodnotami.




Obr. č. 44: Výstup testování 1 se znázorněnými chybami.

Výsledné hodnoty jsou nastaveny od hodnoty 0 do 1, kde 1 je skutečná výsledná hodnota abnormality.




Obr. č. 45: Výstup testování 2 se znázorněnými chybami.




Obr. č. 46: Výstup testování 3 se znázorněnými chybami.





Obr. č. 47: Výstup testování 4 se znázorněnými chybami.



Obr. č. 48: Výstup testování 7 se znázorněnými chybami.

Obrázky č. 47 a 48 jsou výstupem testování modelu NNTS, které jsou bez výsledných hodnot neboli bez zamrznutí pohybu. Dříve bylo zmíněno nastavení výsledných hodnot, kde při hodnotě jedna dochází k zamrznutí pohybu tzv. výsledné indikátory/hodnoty. Vytvořený model NNTS je schopen s velkou přesností odhadnout výsledné hodnoty/indikátory.

Metoda NNTS fungující na principu dynamického filtrování, kde se hodnoty natrénované sítě používají k detekci anomálií k nově vloženému setu dat. Při trénování vychází hodnota regrese 99,6 %. Přesnost detekce zamrznutí pohybu je poté zobrazena v grafech, kde lze vidět odpovídající přesnost přes 99 %. Síť byla také testována na datech bez vykazujících „anomálií“ a průběh detekce je také znázorněn v grafu. Průměrná hodnota regrese při testování dat byla 99,4 %.

Pro detekování zamrznutí pohybu je výhodnější použití sítě NNTS z důvodu velké přesnosti detekce zamrznutí a také schopnosti pracovat s velkým množstvím dat bez potřeby předzpracování dat ke trénování k požadované přesnosti.

Tab. č. 13: Výsledné přesnosti testovaných NN

	<b>PŘESNOST</b>
Testování NNTS	>99%
Testování NNPR	49,5%

# ZÁVĚR

Cílem této diplomové práce bylo vytvořit algoritmus pro detekci poruch chůze pacientů s Parkinsonovým onemocněním, za použití přístrojů Xsens Awinda a Novel Emed-XL.

Práce započala studiem problematiky naměření dat s využitím inerciálních senzorů a také problematiky detekce poruch chůze, konkrétně jevu navázaného v anglické literatuře „freezing“ pacientů s Parkinsonovým onemocněním. Je zde zdokumentována také problematika detekování poruch chůze s využitím metod založených na neuronových sítích používající celé záznamy chůze, tzv.: hrubé data pomocí tříosých akcelerometrů. Informace získané z těchto studií byly uvedeny v první kapitole této práce.

Následně je popsána Parkinsonova nemoc, její historie, fyziologický původ a působení na nemocnou osobu. Společně s popsáním působení nemoci byla popsána struktura chůze pro porovnání mezi pacienty s Parkinsonovým onemocněním a zdravými osobami, k výslednému zhodnocení rozdílu v pohybu osob. Následně byly popsány využití přístroje Xsens Awinda, Novel Emed-XL a způsob přípravy měření. Poslední částí přípravy bylo vybrání metod pro detekci zamrznutí pohybu dle provedené rešerše, kde bylo vybráno využití neuronových sítí.

V praktické části je nejprve popsán experiment a samotné měření s přístroji. Problematika záznamu měřených dat těchto přístrojů byla zjednodušena hardwarovou synchronizací. Byla také vytvořena databáze pro import a export naměřených dat.

Byl vybrán jeden parametr – doba trvání kroku, který byl vyhodnocen jak nad skupinou zdravých osob, které byly získány měřením na upraveném systému. Stejný parametr byl vyhodnocen i ze získaných volně dostupných databází záznamů pohybů osob s PN. Z provedených testů a porovnávání bylo zjištěno, že rozdíly v pohybu osob mezi zdravými a nemocnými pacienty je až na některé parametry poměrně zanedbatelný. S největšími rozdíly ve variabilitě času potřebného k dokončení kroku, kdy zdraví pacienti měli mnohem menší variabilitu doby kroku.

Dále byly vybrány a implementovány 2 metody detekce zamrznutí pohybu pomocí neuronové sítě. Obě metody byly testovány na hodnotách z volně dostupných záznamů pohybů osob s Parkinsonovým onemocněním. Výsledkem testování je, že metoda NNTS je lepší než metoda NNPR. Z testovaných neuronových sítí pro detekci zamrznutí pohybu bylo zjištěno, že pattern recognition algoritmus, NNPR je schopen detekovat zamrznutí pohybu pouze v 49.5 % případů a Time series algoritmus, NNTS je schopen detekovat zamrznutí pohybu s více než 90 % přesností. Metoda NNPR je jedna z nejpoužívanějších metod pro detekování anomálií v datovém signálu. Ze zpracované rešeršní části [1] vyplývá její velká přesnost při předzpracovaném datech a dostatečném množství vstupních dat. Přesnost metody NNTS pro hledání anomálií je potvrzena v rešeršní části. [10], kde byla testována na velké množství vstupních dat s problematikou hledání anomálie.

# LITERATURA

- [1] AHLRICHS, Claas, Albert SAMÀ, Michael LAWO, et al. *Detecting freezing of gait with a tri-axial accelerometer in Parkinson's disease patients*. 2016, **54**(1), 223-233. DOI: 10.1007/s11517-015-1395-3. ISSN 0140-0118. Dostupné také z: <http://link.springer.com/10.1007/s11517-015-1395-3>
- [2] HAJI GHASSEMI, Nooshin, Julius HANNINK, Christine MARTINDALE, Heiko GABNER, Meinard MÜLLER, Jochen KLUCKEN a Björn ESKOFIER. Segmentation of Gait Sequences in Sensor-Based Movement Analysis: A Comparison of Methods in Parkinson's Disease. *Sensors*. 2018, **18**(2). DOI: 10.3390/s18010145. ISSN 1424-8220. Dostupné také z: <http://www.mdpi.com/1424-8220/18/1/145>
- [3] KRÁLOVÁ, Hana. *Parkinsonova nemoc – ošetrovateľská problematika pokročilého štádia*. Pardubice, 2012. Diplomová práce. Univerzita Pardubice. Vedoucí práce MUDr. Václav Dostál.
- [4] LEVINE, David, Jim RICHARDS a Michael W. WHITTLE. *Whittle's Gait Analysis*. Elsevier Health Sciences, c2012. ISBN 0198576102.
- [5] SAITO, Naoshi, Teiji YAMAMOTO, Yoshihiro SUGIURA, Saori SHIMIZU a Masara SHIMIZU. A New Device for the Long-term Monitoring of Motor Activities for Parkinson's Disease. *Lifecorder*. Fukushima Medical University, 2004, **2003**(960-1295).
- [6] BIENKIEWICZ, Marta M. N., Cathy CRAIG a Marta M. N. BIENKIEWICZ. Sound, Music and Movement in Parkinson's Disease. *Frontiers Media*, c2017. ISBN 9782889450794.
- [7] DELISA, Joel A. *Gait Analysis in the Science of Rehabilitation*. Illustrated. United States: DIANE Publishing, 1998. ISBN 0756700213.
- [8] AICH, Satyabrata, Pyari PRADHAN, Jinse PARK, Nitin SETHI, Vemula VATHSA a Hee-Cheol KIM. A Validation Study of Freezing of Gait (FoG) Detection and Machine-Learning-Based FoG Prediction Using Estimated Gait Characteristics with a Wearable Accelerometer. *Sensors* [online]. 2018, **18**(10) [cit. 2019-01-06]. DOI: 10.3390/s18103287. ISSN 1424-8220. Dostupné z: <http://www.mdpi.com/1424-8220/18/10/3287>
- [9] Samà A, Pérez C, Rodríguez-Martin D, Cabestany J, Moreno Aróstegui JM, Rodríguez-Molinero A (2013) A heterogeneous database for movement knowledge extraction in Parkinson's disease. In: European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning
- [10] RONG, Zhang a Dong SHANDONG. Feedforward Neural Network for Time Series Anomaly Detection. Singapore, 2018.
- [11] J. Contreras, R. Espinola, F. J. Nogales, and A. J. Conejo, Arima models to predict next-day electricity prices, *IEEE transactions on power systems*, vol. 18, no. 3, pp. 1014–1020, 2003.

- [12] H. Z. Moayedi and M. Masnadi-Shirazi, Arima model for network traffic prediction and anomaly detection, in *Information Technology*, 2008. ITSIm 2008. International Symposium on, vol. 4, pp. 1–6, IEEE, 2008.
- [13] C. Chatfield and M. Yar, Holt-winters forecasting: some practical issues, *The Statistician*, pp. 129–140, 1988.
- [14] ROKŮSEK, Zdeněk. *Teoretické základy neuronových sítí*. České Budějovice, 2007. Bakalářská práce. Jihočeská Univerzita v Českých Budějovicích, Pedagogická fakulta. Vedoucí práce Mgr. Petr Bartoš.
- [15] *Neuronová síť* [online]. [cit. 2019-04-29]. Dostupné z: [http://www.trilobyte.cz/downloadfree/qcmanual/neural\\_net.pdf](http://www.trilobyte.cz/downloadfree/qcmanual/neural_net.pdf)
- [16] Neuronové síť. *Mendel* [online]. Brno [cit. 2019-04-29]. Dostupné z: [https://is.mendelu.cz/eknihovna/opory/zobraz\\_cast.pl?cast=21471](https://is.mendelu.cz/eknihovna/opory/zobraz_cast.pl?cast=21471)
- [17] *MVN User manual* [online]. Xsens [cit. 2019-04-29]. Dostupné z: [https://xsens.com/download/usermanual/3DBM/MVN\\_User\\_Manual.pdf](https://xsens.com/download/usermanual/3DBM/MVN_User_Manual.pdf)
- [18] BLAHA, Milan. *Úvod do zpracování časově závislých dat neuronovými sítěmi* [online]. VUT FEKT Brno, 2003 [cit. 2019-04-29]. Dostupné z: <http://www.elektrorevue.cz/clanky/03031/index.html>
- [19] *Emed General Manual: Version 23* [online]. [cit. 2019-06-21]. Dostupné z: <http://www.novelusa.com/index.php?fuseaction=support.manuals>
- [20] Bi-Directional Logic Level Converter Hookup Guide. *SparkFun* [online]. 2013 [cit. 2019-06-22]. Dostupné z: [https://learn.sparkfun.com/tutorials/bi-directional-logic-level-converter-hookup-guide?\\_ga=2.72927251.1821612662.1561203263-945169071.1546865139](https://learn.sparkfun.com/tutorials/bi-directional-logic-level-converter-hookup-guide?_ga=2.72927251.1821612662.1561203263-945169071.1546865139)
- [21] Activation functions in neural networks. *Towards Data Science* [online]. 2017 [cit. 2019-07-10]. Dostupné z: <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>
- [22] ReLU and Softmax Activation Functions. *GitHub* [online]. 2017 [cit. 2019-07-10]. Dostupné z: <https://github.com/Kulbear/deep-learning-nano-foundation/wiki/ReLU-and-Softmax-Activation-Functions>
- [23] Understand the Softmax Function in Minutes. *Medium* [online]. 2018 [cit. 2019-07-10]. Dostupné z: <https://medium.com/data-science-bootcamp/understand-the-softmax-function-in-minutes-f3a59641e86d>
- [24] NAYAK, Sasmita, Neeraj KUMAR a B. B. CHOUDHURY. Scaled Conjugate Gradient Backpropagation Algorithm for Selection of Industrial Robots. *International Journal of Computer Application* [online]. India, 2017, 2017, 7(No.6), 1797-2250 [cit. 2019-07-10]. DOI: <https://dx.doi.org/10.26808/rs.ca.i7v6.12>. Dostupné z: <https://dx.doi.org/10.26808/rs.ca.i7v6.12>
- [25] MOLLER, Martin F. *Computer Science Department University of Aarhus, Denmark* [online]. November 13, 1990 [cit. 2019-07-10].

- [26] Shallow Neural Network Time-Series Prediction and Modeling. *MathWorks* [online]. [cit. 2019-07-10]. Dostupné z: <https://www.mathworks.com/help/deeplearning/gs/neural-network-time-series-prediction-and-modeling.html>
- [27] PUJOL, Jose. The solution of nonlinear inverse problems and the Levenberg-Marquardt method. *GEOPHYSICS* [online]. 2007, 1968, **72**(4), W1-W16 [cit. 2019-07-10]. DOI: 10.1190/1.2732552. ISSN 0016-8033. Dostupné z: <http://library.seg.org/doi/10.1190/1.2732552>
- [28] GAVIN, Henri P. The Levenberg-Marquardt algorithm for nonlinear least squares curve-fitting problems [online]. 2019 [cit. 2019-07-10]. Duke University.
- [29] BURDEN, Frank a Dave WINKLER. Bayesian Regularization of Neural Networks. *Artificial Neural Networks*[online]. Totowa, NJ: Humana Press, 2009, 2008, , 23-42 [cit. 2019-07-10]. Methods in Molecular Biology™. DOI: 10.1007/978-1-60327-101-1\_3. ISBN 978-1-58829-718-1. Dostupné z: [http://link.springer.com/10.1007/978-1-60327-101-1\\_3](http://link.springer.com/10.1007/978-1-60327-101-1_3)
- [30] SHIBUYA, Naoki. Demystifying Cross-Entropy. *Towards Data Science* [online]. Oct 28, 2018 [cit. 2019-07-10]. Dostupné z: <https://towardsdatascience.com/demystifying-cross-entropy-e80e3ad54a8>
- [31] Differences between L1 and L2 as Loss Function and Regularization. *Chioka* [online]. 2013 [cit. 2019-07-11]. Dostupné z: <http://www.chioka.in/differences-between-l1-and-l2-as-loss-function-and-regularization/>
- [32] SILVA DE LIMA, Ana Lúcia, Luc J. W. EVERS, Tim HAHN, et al. Freezing of gait and fall detection in Parkinson's disease using wearable sensors: a systematic review. *Journal of Neurology* [online]. 2017, **264**(8), 1642-1654 [cit. 2019-07-11]. DOI: 10.1007/s00415-017-8424-0. ISSN 0340-5354. Dostupné z: <http://link.springer.com/10.1007/s00415-017-8424-0>

# SEZNAM PŘÍLOH

Příloha 1: CD

Přiložené CD obsahuje:

- Diplomovou práci ve formátu.pdf s označením DPSUC0066.pdf
- Složku Datasets
  - obsahuje soubor datasets.pdf s popsányými datovými sety, které byli použity a odkazy na tyto datové sety ke stažení.
- Složku Měření
  - obsahuje soubor database.pdf s popsáním postupem k připojení se do databáze a stažení dat z této databáze.
  - obsahuje soubory jednotlivých měření k otestování algoritmů.
- Složku Algoritmy
  - Obsahuje soubor Diplomka.mat
  - Obsahuje soubor load.mat